

Ein PreCrash-System auf Basis multisensorieller Umgebungserfassung

von der Fakultät für Elektrotechnik und Informationstechnik
der Technischen Universität Chemnitz

genehmigte

Dissertation
zur Erlangung des akademischen Grades

Doktoringenieur
(Dr.-Ing.)

vorgelegt von
Dipl.-Ing. Michael Skutek
geboren am 16. Mai 1976 in Karl-Marx-Stadt

eingereicht am 24. Januar 2006

Gutachter: Prof. Dr.-Ing. G. Wanielik
Prof. Dr.-Ing. M. Chandra
Dr.-Ing. J. Dickmann

Tag der Verleihung: 20. September 2006

Das in dieser Dissertation beschriebene PreCrash-System wie auch die Dissertation selbst entstanden im Rahmen von Arbeiten innerhalb des EU-Projekts APALACI, einem Unterprojekt des EU-Vorhabens PReVENT. Ziel dieser europäischen Förderinitiative ist die erhebliche Verbesserung der Sicherheit und damit eine deutliche Reduktion von Opfern im Straßenverkehr. Innerhalb des APALACI-Projektes stehen die Entwicklung, Realisierung und die Demonstration eines Systems zur Verbesserung der Unfall-Prävention bzw. Unfallschwere-Reduktion im Vordergrund. Die erfolgten Arbeiten leisten hierfür einen Beitrag durch die Entwicklung eines Systems, welches Unfälle schon vor dem eigentlichen Unfallbeginn erkennen soll.

Konzeption, Implementation und ausführliche Tests fanden innerhalb des DaimlerChrysler-Forschungszentrums in Ulm statt. Alle zur Arbeit benötigten Mittel inklusive der Versuchsfahrzeuge stellte die Abteilung REI/AU zur Verfügung. Hierfür und für die über etwas mehr als vier Jahre dauernde, sehr gute Zusammenarbeit und Unterstützung möchte ich den Kollegen dort danken; insbesondere unserem Teamleiter Dr.-Ing. Jürgen Dickmann, der die Durch- und Weiterführung der Arbeiten am Forschungszentrum überhaupt erst ermöglichte, dem Kollegen Dr.-Ing. Moheb Mekhaïel, der mir mit fachlichem Rat und aktiver Unterstützung zur Seite stand, dem Kollegen Nils Appenrodt für viele Fragen, Anregungen und vor allem für die Erledigung der Organisation des EU-Projekts und den Kollegen Wolff Luik und Michael Hieber, die in der Werkstatt viele notwendige Auf- und Umbauten an den Versuchsträgern durchführten.

Zwei weitere Kollegen trugen durch unzählige fachliche Diskussionen und ihre aktive Unterstützung zum Gelingen des Projekts bei: Prasanna und mein „Gegenüber“ Dirk Linzmeier.

Ein wichtiger Teil der Unterstützung für diese Arbeiten kam von meinem Betreuer Prof. Dr.-Ing. Wanielik, der mir die Möglichkeit der Promotion verschaffte, mit fachlichem Rat zur Seite stand und mir große Freiheiten bei den Arbeiten innerhalb des Forschungszentrums ließ.

Dank geht auch an alle Studenten, die mich durch ihre Mitarbeit unterstützten und ohne die Implementation und die vielen Tests des Systems nicht in dem Umfang innerhalb des kurzen Zeitrahmens möglich gewesen wären: Jochen (Jürgen) Mühlhäusser, Min Wu, Thomas Rolfes, Benjamin Müller, Christoph Moll, Peter Doliwa, Martin Prokop, Mustafa Uzunali und Matthias Keller.

Bad Westernkotten, Januar 2006

Inhaltsverzeichnis

Glossar	7
Formelzeichen	9
1 Einleitung	15
1.1 Umfelderkennung im Automobilbereich	15
1.2 Inhalt und Aufbau der Arbeit	19
1.3 PreCrash - Funktionsbeschreibung	19
1.4 PreCrash - Anforderungen an das System und die Sensorik	23
1.5 PreCrash - Logischer Systemaufbau	25
2 Beschreibung der Sensorik	27
2.1 Mechanischer Aufbau des Systems	27
2.2 Radar	28
2.2.1 Funktionsweise	28
2.2.2 Randbedingungen	28
2.2.3 Spezifikation der verwendeten Sensoren	33
2.3 Laserscanner	33
2.3.1 Aufbau und Funktionsweise	33
2.3.2 Randbedingungen	34
2.3.3 Spezifikation des verwendeten Sensors	39
2.4 Gegenüberstellung der beiden Sensoren	40
3 Grundlegende Betrachtungen zur Fusion	43
3.1 Sensordatenfusion	43
3.1.1 Begriffsdefinitionen	43
3.1.2 Ziele und Potential von Sensordatenfusionsansätzen	44
3.1.3 Nachteile der Sensordatenfusion	44
3.1.4 Unterscheidungskriterien	45
3.1.5 Werkzeuge zur Sensordatenfusion	48
3.2 Sensordatenfusion von Nahbereichsradaren und Laserscanner	49
3.2.1 Nutzen der Sensordatenfusion	49
3.2.2 Nachteile und Probleme der Fusion von Laserscanner und Radar	51
3.2.3 Weitere Anwendungen	52
4 Einzelsignalverarbeitung der für die Fusion genutzten Sensortypen	53
4.1 Signalverarbeitung für die Radarsensoren	54
4.1.1 Fusion der Radare mittels Triangulation	54
4.1.2 Fusion der Radare mittels Grid of Evidence	57

4.1.3	Fusion der Radare mittels Klassifikator	59
4.2	Signalverarbeitung für den Laserscanner	63
4.2.1	Segmentierung, Filterung und Fusion der Rohdaten	63
4.2.2	Merkmalsextraktion	70
4.3	Tracking	75
4.3.1	Alpha-Beta-Tracker	76
4.3.2	Kalman-Filter	76
4.3.3	Assoziation	82
4.3.4	Erweiterungen	84
4.4	Sensorausfall-Erkennung	87
4.4.1	Fehlerarten	87
4.4.2	Bekannte Ansätze zur Fehlererkennung	88
4.4.3	Stochastisches Verfahren zur Fehlererkennung	91
5	Fusionsansätze	97
5.1	Zeitliche Aspekte der Signalverarbeitung	97
5.2	Bekannte Verfahren zur Fusion der Sensordaten	101
5.2.1	Messwerte-Fusion	101
5.2.2	Track-to-Track-Fusion	102
5.3	Implementierte Verfahren	104
5.3.1	Messvektor-Fusion	104
5.3.2	Fusion mittels Segmentierungsgitter	107
6	Umfeldbeschreibung und Entscheidungsalgorithmen	111
6.1	Umfeldbeschreibung und Vorhersage	112
6.2	Entscheidungsverfahren in Einzelsensorsystemen	115
6.2.1	Entscheidung mittels Limit	115
6.2.2	Entscheidung mittels Klassifikation	116
6.3	Entscheidungsverfahren bei mehreren Sensoren	117
6.3.1	Klassifikation und logische Verknüpfung	117
6.3.2	Klassifikation und Dempster-Shafer-Kombination	118
7	Ergebnisse	125
7.1	Randbedingungen	125
7.1.1	Datensätze	125
7.1.2	Systemstruktur und Algorithmen	127
7.2	Ergebnisse und Vergleich	128
7.2.1	Tracking-Algorithmus	128
7.2.2	Sensorausfallerkennung	131
7.2.3	Gewinn an Robustheit durch Fusion	134
7.2.4	Entscheidungsstufe und Gesamtfunktionalität	135
8	Zusammenfassung	141

Glossar

ABS

Antiblockiersystem

ACC

Adaptive Cruise Control

ARCNet

Attached Resources Computer Network

BmBF

Bundesministerium für Bildung und Forschung

CAN

Controller Area Network

DARPA

Defense Advanced Research Projects Agency

ESP

Elektronisches Stabilitätsprogramm

JPDA

Joint Probabilistic Data Association

Laser

Light Amplification by Stimulated Emission of Radiation

PDA

Probabilistic Data Association

Radar

RAdio Detection And Ranging

TDC

Time-to-Digital-Converter

Formelzeichen

α	Kontextabhängig Absorptionskoeffizient, Wichtungsfaktor oder Winkel
$\bar{\nu}$	Mittelwert der Innovation
β	Kontextabhängig Absorptionskoeffizient, Wichtungsfaktor oder Winkel
ν	Innovation
ϵ_{s_k}	Fehler
η	Schwellwert für Entscheidung der Sensorausfallerkennung
γ	Winkelauflösung
$\hat{\mathbf{s}}$	Zustandsschätzung (mehrdimensional)
$\hat{\mathbf{s}}^-$	Prädiktion eines Zustandes (mehrdimensional)
\hat{s}	Zustandsschätzung (eindimensional)
\hat{s}^-	Prädiktion eines Zustandes (eindimensional)
λ	Wellenlänge
μ	Mittelwert
ω	Kreisfrequenz
ϕ_0	Phasenwinkel
ρ	Koordinate im (ρ, θ) -Raum
σ	Varianz
σ_R	Radarrückstreuquerschnitt
τ_P	Pulsdauer
A	Zustandsübergangsmatrix
B	Rückführungsmatrix
C	Messmatrix
D	Systemparametermatrix

Abkürzungen und Formelzeichen

\mathbf{d}_m	Abstand (mehrdimensional)
\mathbf{G}	Polinommatrix für Beschreibung eines Systems in Eingang-Ausgangsform
\mathbf{H}	Polinommatrix für Beschreibung eines Systems in Eingang-Ausgangsform
\mathbf{I}	Einheitsmatrix
\mathbf{K}	Kalman Gain (mehrdimensional)
\mathbf{P}	Schätzung des Schätzfehlers
\mathbf{P}^-	Prädiktion des Schätzfehlers
\mathbf{P}_C	Kreuzkovarianzmatrix
$\mathbf{q}(k)$	Vektoren, die Sensorfehler enthalten
\mathbf{Q}^-	Modellfehler
\mathbf{R}	Messfehlerkovarianzmatrix
\mathbf{S}	Innovationskovarianzmatrix
\mathbf{u}	Regeleingriff
\mathbf{v}	Messfehler
\mathbf{W}	Gewichtungsmatrix
$\mathbf{w}(k)$	Vektoren, die unbekannte Einflüsse enthalten
\mathbf{z}	Messung (mehrdimensional)
Θ	Menge
θ	Koordinate im (ρ, θ) -Raum
Θ_B	Beobachtungswinkel
Θ_E	Einfallswinkel
Θ_G	Grenzwinkel der Totalreflexion
$\tilde{\mathbf{s}}$	Abweichung zwischen Prädiktion und wahrem Zustand (mehrdimensional)
\tilde{s}	Abweichung zwischen Prädiktion und wahrem Zustand (eindimensional)
\vec{E}	Elektrische Feldstärke
\vec{E}_0	Amplitude der elektrischen Feldstärke
\vec{H}	Magnetische Feldstärke
\vec{H}_0	Amplitude der magnetischen Feldstärke

ξ	Überlappungsfaktor
A	Elektrisch wirksame Fläche
a	Kontextabhängig Ausbreitungsdämpfung oder Beschleunigung
A_n	Anzahl der Fehlalarme
A_p	Anzahl der Falschalarme
A_Z, A_E	Elektrisch wirksame Fläche (Ziel, Empfänger)
b_i	Verschiebung eines Ziels in y -Richtung (Merkmal)
B_S	Signalbandbreite
$Bel(\dots)$	Grad des Glaubens an eine Annahme
C	Kollisionswahrscheinlichkeit bzw. Aussage zur möglichen Kollision mit einem Objekt
c	Kern einer Massefunktion
c_0	Phasengeschwindigkeit einer elektromagnetischen Welle in einem homogenen, verlustfreien Medium
c_c	Konstante für Dekrementierung des Ausfallzählers
c_l	Laufzeit eines Laserimpulses in Luft
c_p	Konstante für Inkrementierung des Ausfallzählers
c_r	Ausbreitungsgeschwindigkeit von elektromagnetischen Wellen
$c_{i,j}$	Grenzwerte für Attribute
D	Statistische Distanz
d	Strecke, Distanz
d_k	Ausfallzähler
D_p	Detektionsrate
F	Fensterbreite
f	Frequenz
F_a	Fehlalarmrate
f_A	Abtastfrequenz
F_p	Falschalarmrate
f_P	Pulsfolgefrequenz

Abkürzungen und Formelzeichen

f_S	Sendefrequenz
G	Antennengewinn
h	Plancksches Wirkungsquantum
I	Intensität
i	Laufindex
I_0	Lichtintensitätswert an der Lichtquelle
I_S	Die für den Absorber typische Sättigungsintensität
j	Laufindex
K	Kontextabhängig für Kalman Gain (eindimensional) oder Maß für Widerspruch
k	Kontextabhängig Wellenzahl oder Laufindex
k_k	Minimal benötigte Anzahl von Zyklen für die Erkennung eines Sensorausfalls
L	Limit
l	Laufindex
M	Gitterindex
$m(\dots)$	Masse
$m_{x,y}$	Zellenindex
N	Anzahl
n	Anzahl
n_S	Brechungsindex
P	Wahrscheinlichkeit
p	Kontextabhängig Impuls eines Photons oder Wahrscheinlichkeit
P_S	Sendeleistung
p_s	Schwerpunkt
$PL(\dots)$	Plausibility
R, R_p, R_s	Reflexionsgrad (parallel bzw. senkrecht zur Einfallsebene)
r_{ein}	Eindeutigkeitsbereich bei der Entfernungsmessung
r_{max}	Größte Entfernung, in der typische Objekte noch detektiert werden müssen
r_{min}	Kleinste Entfernung, in der typische Objekte noch detektiert werden müssen

s	Zustand
$S(X)$	Leistungsdichte im Fall von $X = r$, sonst Grad des Glaubens an eine Annahme
S_K	Skalierungsfaktor
s_M	Zustandsänderung
S_{μ_j}	Schwellwert für Fehlererkennungsverfahren
S_{μ_m}	Schwellwert für Fehlererkennungsverfahren
s_{AB}	Abstand zwischen zwei Punkten A und B
T	Periodendauer
t	Zeit
t_a	Zeit, die die Aktuatorik zur Auslösung benötigt
t_c	Zeit bis zum Aufprall
t_l	Laufzeit
t_o	Zeit, die zusätzlich zur Auslösezeit der Aktuatorik hinzukommt (Offset)
T_S	Periodendauer des gesendeten Signals
t_s	Zeit, um die ein Empfangssignal verschoben wird
T_T	Transmissionsgrad
t_z	Messzykluszeit
t_{lV}	Laufzeit durch ein einzelnes Verzögerungsglied
t_{sc}	Zeitschwellwert; bezeichnet die Auslöseschwelle des PreCrash-Systems und ist von Relativgeschwindigkeit und benötigter Vorwarnzeit abhängig
T_{T0}	Transmissionsgrad bei niedrigen Intensitäten im Bereich der linearen Absorption
T_{Tot}	Totzeit (Verarbeitungszeit)
v	Geschwindigkeit
$v_{i,j}$	Attribute
$v_{rel,max}$	Größte Relativgeschwindigkeit zwischen Objekt und eigenem Fahrzeug, bei dem das System noch funktionieren muss
$v_{rel,min}$	Kleinste Relativgeschwindigkeit zwischen Objekt und eigenem Fahrzeug, bei dem das System noch funktionieren muss
W	Einem Photon zugeordnete Energie

Abkürzungen und Formelzeichen

w_{\dots} Wichtungsfaktor

x Positionsangabe in kartesischen Koordinaten (x -Komponente)

y Positionsangabe in kartesischen Koordinaten (y -Komponente)

z Positionswert in z -Richtung

1 Einleitung

1.1 Umfelderkennung im Automobilbereich

Moderne Kraftfahrzeuge bieten Komforteinrichtungen wie Klimaanlage, elektrische Einstellmöglichkeiten für Spiegel oder Sitze und Navigationssysteme. Hinzu kommen Assistenzsysteme, die den Fahrer bei normaler Fahrt entlasten sollen und damit hauptsächlich ebenso dem Komfort dienen. Ein Beispiel hierfür sind Tempomaten, die eine konstante Geschwindigkeit auch über längere Strecken halten.

Daneben rüsten die Hersteller ihre Fahrzeuge auch mit einer wachsenden Anzahl von Sicherheitseinrichtungen wie ABS, Airbags, ESP und (reversiblen) Gurtstraffern mit Gurtkraftbegrenzern aus. Nicht zuletzt kommen die Fahrzeuge mit immer weiter verbesserten Fahrgastzellen und Knautschzonen auf den Markt. Ziel der wachsenden Ausrüstung mit Sicherheitssystemen ist die Reduktion von Unfallzahlen bzw. Unfallfolgen bei immer weiter steigender Verkehrsdichte. Dieses Ziel geht sogar bis hin zur „Vision des unfallfreien Fahrens“ [hig04].




Abbildung 1.1: Sicherheitssysteme im Automobilbereich

Abbildung 1.1 zeigt eine Systematik von Sicherheitssystemen in Kraftfahrzeugen zur Vermeidung von Unfällen oder zur Verminderung der Unfallfolgen. Ausgehend von der Zeit bis zu einem etwaigen Unfall und der Zeit nach diesem Ereignis reihen sich verschiedene Systeme aneinander an. So unterstützen informierende oder warnende Systeme den Fahrer während der Fahrt durch aufbereitete Informationen über eine geeignete Mensch-Maschine-Schnittstelle. Zu Beginn kritischer Situation helfen unterstützende Systeme dem Fahrer, sein Fahrzeug zu stabilisieren oder einen drohenden Unfall abzuwenden. In Situationen, in denen ein (in der Regel unvermeidbarer) Unfall kurz bevorsteht, sorgen eingreifende oder vorauslösende, meist reversible Systeme für eine Milderung der Unfallfolgen.

Die Sicherheitseinrichtungen, die während und nach dem Unfall zum Einsatz kommen, richten sich nach der Schwere des Aufpralls. So dienen zum Beispiel Schutzsysteme für Bagatellschäden vor allem der Verringerung oder gar der kompletten Vermeidung von Reparatur-

1 Einleitung

kosten. Insassenschutzsysteme werden abhängig von der Schwere des Unfalls in verschiedenen Stufen aktiviert.

Bei der Rettung von Insassen nach dem Unfall können automatische Notrufsysteme helfen, die Informationen wie Unfallort, Anzahl der Personen im Fahrzeug bis hin zu Unfalldaten (Beschleunigung, Beschleunigungsrichtung, Abschätzung der Unfallschwere) oder medizinische Daten der Insassen (Pulsfrequenz, Atemfrequenz, etc.) an eine Rettungsleitstelle zu übertragen.




Abbildung 1.2: Umfelder kennende Systeme im Automobilbereich

Viele Komfort- und Sicherheitssysteme für Fahrzeuge setzen Informationen bezüglich des Fahrzeugumfeldes voraus oder bieten unter Verwendung von Wissen über das aktuelle Fahrzeugumfeld erweiterte Funktionalität oder einen zuverlässigeren Betrieb. Abbildung 1.2 zeigt einen (aufgrund der Anzahl an denkbaren und bereits existierenden Systemen nicht vollständigen) Überblick zu Anwendungen, welche mit Hilfe von Umfeldererkennung¹ bzw. umfelder kennenden Systemen arbeiten.

So hängen vor allem Assistenzsysteme im Komfortbereich wie z. B. Einparkhilfe oder „intelligente“ Tempomaten (ACC) von zuverlässigen Informationen über das aktuelle Umfeld des Fahrzeuges ab. Doch auch Sicherheitssysteme wie zum Beispiel Fußgängerschutzsysteme [LMDD04, FLD03] oder Spurwechselassistenten benötigen Informationen bezüglich der Situation des Fahrzeugumfeldes. In Abhängigkeit von Vorhandensein oder der Stärke eines (teil-)autonomen Fahreingriffs sind Detektion und Darstellung von Objekten im Fahrzeugumfeld (informierende/warnende Systeme) bis hin zu weitergehenden Schritten wie Interpretation von Szenen, Objekt-Klassifikation, Entscheidungen und Regelung notwendig.

Käufer akzeptieren Fehlverhalten teurer Assistenzsysteme nur in einem sehr geringen Maße. Für Sicherheitsanwendungen sind die Anforderungen an die Zuverlässigkeit noch um einiges

¹Der Begriff Umfeldererkennung ist hier nicht streng auf das *Fahrzeugumfeld* bezogen, da innenraumüberwachende Systeme oft sehr ähnlich funktionieren.

höher als bei Komfortsystemen. Die gelieferte Information muss im Gegensatz zu Komfortsystemen möglichst in jeder Fahrzeugsituation verlässlich vorliegen. In [JLRW04] ist eine tiefergehende Darstellung dieser Problematik zu finden.

Die Realisierung umfelder kennender Systeme bzw. kompletter Anwendungen, die auf umfelder kennenden Systemen basieren, ist Forschungsgegenstand von Arbeiten sowohl in staatlichen Forschungseinrichtungen als auch in Forschungs- und Entwicklungsabteilungen von Firmen. Viele Systeme entstanden und entstehen auch weiterhin auf der Basis von Einzelsensorsystemen; die Fusion der Daten verschiedener Sensoren nimmt jedoch einen immer größeren Anteil der Arbeiten ein.

So beschäftigen sich zum Beispiel die Hersteller von Kraftfahrzeugen und Zulieferer intensiv mit dieser Thematik. Nur einige ausgewählte Beispiele hierfür sind Projekte aus dem Komfortbereich wie

ein *Einparkassistent für Tiefgaragen* (DaimlerChrysler AG) [SSK03]

oder Sicherheitsanwendungen wie

ein auf Nahbereichsradaren basierendes *PreCrash-System* (DaimlerChrysler AG) [SMW03],

Ansätze für *Kreuzungsassistenzsysteme* (DaimlerChrysler AG) [GWF03],

eine *Erweiterung eines ACC-Systems durch PreCrash-Funktionalität* (Toyota Motor Corporation) [TKK⁺03],

ein *PreCrash-System basierend auf der Sensordatenfusion eines Radars und einer Kamera* (Toyota Motor Corporation) [TMK⁺04],

Spurhalteassistenten (Honda) [IG04]

oder die jeweiligen Applikationen unterstützende Projekte und Entwicklungen wie

Objektklassifikation mit Nahbereichsradaren (Technische Universität Hamburg-Harburg, Volkswagen AG) [KFA⁺04],

die *Entwicklung bildgebender Radarsensoren* (DaimlerChrysler AG) [MS03],

Systeme zur *Umfeldererkennung (speziell Verkehrsschilder und Straßenmarkierungen) basierend auf der Fusion von Kamera und digitalen Karten* (Robert Bosch GmbH) [JN04]

bis hin zu ambitionierten Zielen wie

Autonomes Fahren (Volkswagen AG) [Bec02].

Die ersten Ergebnisse dieser und ähnlicher Arbeiten kamen bereits in Form von Serienprodukten – meist noch als Einzelsensorsysteme – auf den Markt. Einige Beispiele für solche Produkte sind ACC-Anwendungen verschiedener Hersteller, erste PreCrash-Systeme von Honda und Toyota, sowie ein Spurhalteassistent von Citroën.

Umgebungserfassungssysteme sind auch im militärischen Bereich, zum Beispiel für die Erfassung von Zielen oder zur Entwicklung autonomer Fahrzeuge, ein wichtiges Thema und mit den Umgebungserfassungssystemen für zivile Fahrzeuge teilweise verwandt. Als Beispiel seien hier Aufbauten autonomer Fahrzeuge für den *DARPA Grand Challenge (DGC)* genannt: [BSG⁺04, ORB04].

In staatlichen Forschungseinrichtungen wie Universitäten entwickelte sich diese Thematik nicht selten aus Forschungsarbeiten im Robotikbereich oder überschneidet sich mit diesen. Universitäre Forschung an Themen der Umfeldsensierung im Kraftfahrzeugbereich geschieht meist auf dem Gebiet theoretischer Untersuchungen und als Entwicklung von Teilaspekten oder -systemen; oft in Zusammenarbeit mit Kraftfahrzeugherstellern und Zulieferern.

1 Einleitung

Einige wenige Beispiele aus der großen Menge dieser Arbeiten sind die Entwicklung eines Systems zum *robusten Tracking von Fahrzeugen* (Universität Stuttgart, DaimlerChrysler AG) [GFL01], die Entwicklung von *Algorithmen zur Gefahrenabschätzung am Beispiel eines Systems zur Warnung vor Heckaufprallen* (Massachusetts Inst. of Technology) [YYFK03], *Betrachtungen zu Fahrerassistenzsystemen* (The Australian National Univ.) [FPZ03], die Entwicklung von *Algorithmen zur Detektion und zum Tracking von Objekten mittels Laserscanner* (University of Coimbra-Polo II) [MBN04] oder der Entwurf von *Modellen zur multisensoriellen Erfassung des Fahrzeugumfeldes mit Hilfe von Schätzverfahren* (Technische Universität Chemnitz) [Cra04].

Ein wichtiges Instrument zur Förderung und Lenkung der Forschung an derartigen Thematiken stellen Projekte mit staatlichen Fördermitteln dar. Neben nationalen Einrichtungen wie dem Bundesministerium für Bildung und Forschung (BmBF) tritt die Europäische Union als Förderer entsprechender Projekte auf.

So war PROMETHEUS ein recht frühes Forschungsprogramm [Arc00], welches, unter anderem initiiert von der deutschen Automobilindustrie, von 1986 bis 1994 lief. Innerhalb dieses Programms sollten Konzepte und Lösungen erarbeitet werden, die den Verkehr in Europa mit Hilfe elektronischer Hilfsmittel (Ansatzpunkt Fahrzeugführung) sicherer, wirtschaftlicher, umweltfreundlicher und komfortabler machen. Es entstanden unter anderem Prototypen in Demonstrationsfahrzeugen, die Verkehrsinfrastruktur nutzen, aber auch fahrzeugautonome Systeme wie Regelsysteme für Geschwindigkeit und sicheren Abstand.

Ein weiteres Beispiel ist das EU-Projekt CHAMELEON [TCG00, SIAD03] mit dem Ziel, die Machbarkeit und das Potential eines Systems zur Verminderung von Unfallfolgen mit Hilfe von Umfelderkennung zu bestimmen. Der Evaluierungsprozess, beginnend im Jahre 2000 und andauernd bis 2003, umfasste sowohl die Untersuchung und Bewertung verschiedener Kandidaten für Sicherheits- bzw. Rückhaltesysteme inklusive biomechanischer Simulationen zur Bestimmung der optimalen Konfiguration als auch den Entwurf eines Demonstrationssystems auf Basis eines Versuchsfahrzeuges mit Umfeldsensorik. Als Sensortechnologie kamen 77 GHz-Radar, 24 GHz-Radar, Lidar, Laserscanner und Kamera sowohl in Form von Einzelsensorsystem als auch fusioniert zum Einsatz. Die Fusion von Sensordaten wurde jedoch aufgrund der unterschiedlichen Qualität und Form der Daten der unterschiedlichen Sensortechnologien als sehr schwierig angesehen [SIAD03].

Ein Beispiel für eine vom BmBF geförderte Forschungsinitiative ist INVENT, welche von 2001 bis zum Jahre 2005 lief. Unter anderem entstanden innerhalb dieser Initiative Projekte zur Unterstützung des Fahrers und zur aktiven Sicherheit, die auf einer Umgebungserfassung und -interpretation basieren. Die Optimierung solcher Umgebungserfassungssysteme war ein Thema eines Teilprojekts.

Auch die hier vorgestellte Arbeit ist Teil eines EU-Projekts: APALACI - ein Unterprojekt des EU-Vorhabens PReVENT. PReVENT ist eine europäische Förderinitiative im 6. Rahmenprogramm zur erheblichen Verbesserung der Sicherheit und deutlichen Reduktion von Opfern im Straßenverkehr. Ziel des APALACI-Projektes ist die Entwicklung, Realisierung und Demonstration eines Systems in Fahrzeugen zur Verbesserung der Unfall-Prävention und Verringerung der Unfallschwere durch den Einsatz innovativer Sensoren und die Implementierung robuster Sensorfusionsarchitekturen [SL05].

1.2 Inhalt und Aufbau der Arbeit

Ziel der Arbeit ist der Entwurf eines PreCrash-Systems, welches auf der Fusion der Daten eines Laserscanners und zweier Nahbereichsradare basiert. Neben guten Erkennungsleistungen spielen bei einem solchen System auch die Eignung für den Einsatz im automobilen Umfeld mit all seinen Anforderungen in Bezug auf Robustheit (zum Beispiel gegenüber Wiedereinflüssen), geringe Anforderungen an die Rechenleistung oder die Erkennung eines Sensorausfalls eine große Rolle. Die Arbeit stellt für die meisten Signalverarbeitungsschritte eines solchen Systems verschiedene Ansätze vor. Neben einer ausführlichen Beschreibung sind auch die Eigenschaften dieser Ansätze in Bezug auf Erkennungsleistungen des Systems, benötigtem Rechenaufwand und weiterer wichtiger qualitativer Kriterien dargestellt. Der Vergleich der unterschiedlichen Ansätze stützt sich vor allem auf eine Basis aufgezeichneter und, zur besseren Verdeutlichung einzelner Ergebnisse, simulierter Messdaten.

Die nachfolgenden Abschnitte dieses Einführungskapitels befassen sich mit der Beschreibung der Funktionalität eines PreCrash-Systems, einer Zusammenstellung von Anforderungen eines solchen Systems an die Sensorik und einer kurzen Einführung in den logischen Aufbau des PreCrash-Systems. In Kapitel 2 findet sich die Beschreibung der verwendeten Sensorik und des Aufbaus des Versuchsfahrzeuges. Das nachfolgende Kapitel 3 bietet eine Einführung in die Grundlagen der Sensordatenfusion und geht auf die Besonderheiten der Fusion der ausgewählten Sensortypen ein. Die sensorspezifischen Teile der Signalverarbeitung, die abhängig vom verwendeten Fusionsansatz zum Einsatz kommen, sind in Kapitel 4 beschrieben. Auch ein Ansatz zur Erkennung von Sensorausfällen findet sich in diesem Kapitel. Kapitel 5 stellt zwei Ansätze zur Fusion der Sensordaten vergleichend vor. In Kapitel 6 sind neben Algorithmen zur Beschreibung des Umfelds und zur Vorhersage von Objektbahnen auch Strategien zur Entscheidung bezüglich der Unfallrelevanz von Objekten sowohl für Einzelsensorsysteme als auch für Systeme mit mehreren Sensortypen dargestellt. Die unterschiedlichen Ansätze zur Signalverarbeitung werden in Kapitel 7 anhand aufgenommener Messdatensätze verglichen und abschließend bewertet.

1.3 PreCrash - Funktionsbeschreibung

In modernen Kraftfahrzeugen sind passive Sicherheitssysteme wie Airbags oder Gurtstraffer Standard. Diese Einrichtungen reduzieren in vielen Fällen die Folgen eines Verkehrsunfalls für die Insassen des Fahrzeugs. Ein Problem bei dem Einsatz solcher Systeme ist die zeitgerechte (in den meisten Fällen rechtzeitige) Auslösung dieser Systeme. In der Regel übernehmen Crash-Sensoren diese Aufgabe, die bei Überschreitung einer bestimmten negativen Beschleunigung ansprechen. Diese Sensoren haben jedoch keinen Überblick über die Unfallsituation – viel mehr als Beschleunigung und Bewegungsrichtung des Stoßes während des bereits begonnenen Unfalls können sie nicht bestimmen. Ein umfelderkennendes System kann darüber hinausgehende Informationen bereitstellen. Mit diesen Informationen entsteht dann beispielsweise die Möglichkeit, die Stufe der Airbag-Zündung schon vor dem Beginn des Unfalls festzulegen, schnelle Sitzverstellungen vorzunehmen, Polster aufzublasen oder die

1 Einleitung

Gurtstraffer eher zu aktivieren [AHA05, Sch05]. Die vorzeitige Straffung des Gurtes verringert unter anderem die Gurtlose² und bewirkt außerdem eine verbesserte Sitzposition. Infolgedessen sind die Insassen besser mit dem Auto und dessen (negativer) Beschleunigung verbunden. Crashtests zeigten gerade in den oberen Körperregionen Verbesserungen bei der durch einen Aufprall hervorgerufenen Insassenbelastung [SB05]. Bereits existierende Sicherheitssysteme wie *PreSafe* [hig04, SB05] (Mercedes) können durch die Erkennung kritischer Situationen anhand geeigneter Auswertung der ESP-Sensorik (allerdings noch ohne Wissen bezüglich des aktuellen Fahrzeugumfelds) vorzeitig spezifischere Aktionen ausführen und bieten damit schon einen Vorteil gegenüber herkömmlicher Crash-Sensorik. Nicht zuletzt ist die von einem Umfelderkennungssystem zur Verfügung gestellte Information auch von Systemen nutzbar, die nach dem Unfall eine Abschätzung der Unfallschwere treffen und diesbezüglich auch autonom Notrufe absetzen [IPNDS05].

Ein PreCrash-System sollte im Allgemeinen hierfür die folgenden Informationen bereitstellen:

- Entscheidung über bevorstehenden Unfall
- Zeit bis zum Aufprall
- Relativgeschwindigkeit zwischen eigenem Fahrzeug und Objekt
- Richtung der Relativgeschwindigkeit
- Entfernung zum Objekt
- Aufprallort am Fahrzeug bzw. Überlappungsbreite

Die Klassifizierung des kollidierenden Objekts kann in speziellen Anwendungsfällen ebenfalls gefordert sein.

An die Qualität der Aussagen, insbesondere der Entscheidung selbst, werden unter anderem, abhängig von der auszulösenden Aktuatorik, hohe Anforderungen gestellt. Bezüglich der Entscheidung selbst, ob ein Unfall bevorsteht oder nicht, sind zwei Parameter kennzeichnend:

Definition 1.1 *Falschalarmrate*

Die Falschalarmrate (auch *false positives*) berücksichtigt die Anzahl A_p der Fälle, in denen das PreCrash-System einen bevorstehenden Unfall meldet, obwohl keine Unfallsituation vorliegt. Sie kann auf eine Wegstrecke d , eine Zeit t oder auch auf eine Gesamtzahl n_M von unfallfreien Messaufnahmen bezogen sein:

$$F_p = \frac{A_p}{[d, t, n_M]}. \quad (1.1)$$

²*Gurtlose* ist die Bezeichnung für den Raum zwischen Gurt und Insasse, hervorgerufen durch (dicke) Kleidung oder lockeres Anlegen des Gurtes.

Definition 1.2 *Fehlalarmrate*

Die Fehlalarmrate (auch *false negatives*) berücksichtigt die Anzahl A_n der Fälle, in denen das PreCrash-System keinen bevorstehenden Unfall meldet, obwohl eine Unfallsituation vorliegt. Im Unterschied zur Falschalarmrate ist sie in der Regel nur auf eine Anzahl n_M von Messaufnahmen bezogen, die Unfallsituationen beinhalten:

$$F_n = \frac{A_n}{n_M}. \quad (1.2)$$

Zwischen Fehlalarmrate F_n und *Detektionsrate* D_p besteht der folgende Zusammenhang:

$$D_p = 1 - F_n. \quad (1.3)$$

Die Fehlalarmrate bzw. die mit ihr unmittelbar zusammenhängende Detektionsrate zeigen, wie sicher das System einen bevorstehenden Unfall bzw. bestimmte Unfallsituationen detektieren kann und damit die Zuverlässigkeit in Unfallsituationen. Die Falschalarmrate ist kennzeichnend für die Robustheit des Systems gegenüber alltäglichen Situationen. Beide Werte sollten möglichst gegen 0 gehen. So würde zum Beispiel eine hohe Falschalarmrate von den Nutzern aufgrund häufiger Auslösungen von Sicherheitseinrichtungen ohne erkennbaren Grund nicht akzeptiert. Dies erfordert ein System, welches sehr zuverlässig und vor allem auch robust gegenüber Umwelteinflüssen ist. Für die Bewertung solcher Raten ist die Betrachtung über einen langen Zeitraum t bzw. eine sehr große Wegstrecke d notwendig, um auch für Fahrzeuge mit sehr hohen Fahrleistungen wie beispielsweise Taxis ein akzeptables Systemverhalten zu erreichen.

Weitere qualitative Parameter des Erkennungssystems sind die Genauigkeit der Schätzungen bezüglich der Objektposition, der Relativgeschwindigkeit, der relativen Bewegungsrichtung, der Aufprallposition und der Zeit bis zum Aufprall.

Die Funktionalität eines PreCrash-Systems wird mit Sensoren, die das Umfeld des Fahrzeugs überwachen und einer entsprechenden Signalverarbeitung, basierend auf den Sensordaten, realisiert. In vielen Fällen beschränkt sich der Überwachungsbereich auf den Frontbereich des Fahrzeuges, ist aber ebenso bei entsprechender Sensorausstattung auf Seiten- und Heckbereich ausdehnbar. Abbildung 1.3 zeigt ein Beispiel für einen Überwachungsbereich.

Typische Szenarien, die eine solche Auslegung auf den Frontbereich abdeckt, sind (schräge) Frontalaufpralle, oft mit seitlichem Versatz, auf Hindernisse oder entgegenkommende Fahrzeuge, oder Auffahrunfälle. Diese Unfalltypen treten vor allem im städtischen Bereich häufig auf und stellten nach [TCG00] zusammengenommen einen Anteil von ca. 48 % aller Unfälle.

Die Funktionsweise des hier vorgestellten PreCrash-Systems zur Erkennung eines bevorstehenden Unfalls stellt sich kurz zusammengefasst folgendermaßen dar: Zum Erreichen der PreCrash-Funktionalität liefert die Sensorik Daten zu Position und eventuell auch relativer Geschwindigkeit von erfassten Objekten im Fahrzeugumfeld. Mit Hilfe dieser Daten trifft das PreCrash-System die Entscheidung, ob diese Objekte zu einem Unfall führen werden oder nicht.

Hierfür nutzt das System neben der Bestimmung der Bewegungsrichtung einen „kritischen Abstand“ r_c , der unter anderem durch einen Zeitschwellwert t_{sc} bestimmt ist. Dieser Zeit-




Abbildung 1.3: PreCrash-Überwachungsbereich im Frontbereich des Fahrzeuges

schwellwert hängt zum einen von der Zeit t_a ab, die die Aktuatorik zur Auslösung benötigt und zum anderen von einem definierten Offset

$$t_o = t_{sc} - t_a. \quad (1.4)$$

Die Zykluszeit der Sensorik und die zeitliche Verzögerung, ausgelöst durch die Laufzeit der Information durch die Signalverarbeitung, bestimmen den Wert für diesen (positiven) Zeitversatz. Die Wirkung der meisten Aktuatoren verschlechtert sich nicht durch zu zeitige Auslösung, wohl aber durch zu späte. Somit wirkt sich eine Wahl eines großen Wertes t_o nicht negativ auf die Aktuatorik aus, vergrößert jedoch die Wahrscheinlichkeit von Falschauslösungen: Steigende Werte t_o vergrößern den „kritischen Abstand“ und somit die Gefahr von Fehl- oder Falsch-Detektionen bei gegebenen Messfehlern und Messauflösung (insbesondere im Bezug auf Winkelangaben) der Sensorik. Ein zu großer Wert t_o kann zudem eine Auslöseschwelle t_{sc} bewirken, die schon außerhalb der Zielszenarien von „unvermeidbaren Unfällen“ liegt. Der „kritische Abstand“ r_c ist neben dem Zeitschwellwert t_{sc} noch durch die Relativgeschwindigkeit v_{rel} zwischen Fahrzeug und Objekt bestimmt.

Dieser Abstand bildet die Entscheidungsbasis für das PreCrash-System: Sobald ein oder mehrere Objekte diesen Abstand unterschreiten und die vorausberechnete Objektbahn mit dem eigenen Fahrzeug zusammentrifft, steht ein Unfall bevor, und entsprechende Informationen sind an nachgeschaltete Einrichtungen weiterzuleiten³.

Die geometrischen Abmessungen des „kritischen Bereiches“ zwischen „kritischem Abstand“ und einem Minimalabstand (Fahrzeuggrenze) hängen von den Anforderungen ab; zumeist vom benötigten Öffnungswinkel des Erkennungsbereiches oder dem maximal betrachteten Aufprallwinkel zwischen Fahrzeugachse und Objektbahn. Abbildung 1.3 zeigt ein Beispiel für einen „kritischen Bereich“.

Das in dieser Arbeit vorgestellte System deckt den Frontbereich entsprechend Abbildung 1.3 vor dem Fahrzeug ab und soll Unfälle erkennen, bei denen die Relativgeschwindigkeiten

³Die Entscheidung kann auch noch von weiteren (Neben-)Bedingungen wie z. B. der Objektklasse abhängig gemacht werden, was hier allerdings nicht weiter behandelt wird.

zwischen 20 km/h und 150 km/h betragen. Die benötigte Vorwarnzeit derzeit gebräuchlicher Aktuatorik wie z. B. reversible Gurtstraffer liegt bei ca. 100 ms bis 300 ms. Die Auslegung des PreCrash-Systems legt eine Auslösezeit von $t_{sc} \geq 200$ ms fest.

1.4 PreCrash - Anforderungen an das System und die Sensorik

Die Wahl der Sensorik trägt einen entscheidenden Anteil an der Qualität des Gesamtsystems. Um die beschriebene Funktionalität der PreCrash-Anwendung entsprechend der Spezifikationen zu erfüllen, müssen die eingesetzten Sensoren zur Umfelderkennung bestimmten Anforderungen genügen. Typischerweise hängen viele Anforderungen voneinander ab bzw. beeinflussen sich gegenseitig. Die wichtigsten Anforderungen sind im Folgenden aufgeführt:

Detektionsleistung Das oben beschriebene Sicherheitssystem sollte alle für die Anwendung relevanten Objekte in seinem Sichtfeld innerhalb der spezifizierten Zeit und mit einer ausreichenden Güte detektieren können. Diese Anforderung kann wiederum in verschiedene Unterpunkte aufgeteilt werden:

- **Detektionsfähigkeit in Abhängigkeit der Reflexionseigenschaften typischer Objekte** Die Reflexionseigenschaften verschiedener Objekte ebenso wie das physikalische Grundprinzip der Sensoren sind wichtige die Detektionsleistung beeinflussende Faktoren. In realen Umgebungen ist es fast unmöglich, alle eventuell vorkommenden Objekte mit nur einem Sensortyp verlässlich detektieren zu können. Kombinierte Informationen von Sensoren mit unterschiedlichen physikalischen Grundprinzipien können die Detektionsleistungen eines Umfelderkennungssystems verbessern.
- **Verfügbare Information** Für ein Umfelderkennungssystem sind die Position und die Abmessungen eines Objekts wichtige Informationen. Dafür sollte der Sensor neben Entfernungsangaben auch Informationen zu dem Lagewinkel liefern. Falls Sensoren für ein Objekt typischerweise nur eine oder sehr wenige Messungen liefern, müssen diese von den zum Sensor bzw. eigenen Fahrzeug am nächsten liegenden Punkten der detektierten Objekte sein.
- **Messauflösung** Das System muss schmale Objekte wie Bäume, Pfosten, Masten und ähnliches innerhalb des Sichtbereiches erfassen und zwischen verschiedenen Objekten auch unterscheiden können, wenn sich diese nahe nebeneinander befinden. Die Genauigkeit der Schätzung der Objektgeschwindigkeit, der Bewegungsrichtung und damit auch der Zeit bis zum Aufprall hängen von der Messauflösung ab. Nicht zuletzt bestimmt diese Größe entscheidend die zu einer sicheren Entscheidung notwendige Dauer der Beobachtung eines Objekts. Entsprechend der in Abschnitt 1.3 beschriebenen Auslegung dieses PreCrash-Systems erscheint eine Entfernungsauflösung von ca. 10 cm und eine Winkelauflösung von 1° als sinnvolle Anforderung an die Sensorik.
- **Messgenauigkeit** Die Messgenauigkeit der Sensoren muss, ebenso wie bei der Messauflösung, eine Trennung zwischen nah nebeneinanderliegenden Objekten ermöglichen.

1 Einleitung

Ebenso bestimmt sie ausschlaggebend die Genauigkeit der geschätzten Objekteigenschaften sowie die Dauer der notwendigen Beobachtungszeit eines Objekts für eine sichere Entscheidung.

Messzykluszeit Die maximal im Fahrzeugumfeld auftretenden Relativgeschwindigkeiten sind sehr hoch. Entsprechend der Auslegung in Abschnitt 1.3 können die Relativgeschwindigkeiten zwischen eigenem Fahrzeug und einem Objekt im Umfeld bis zu 150 km/h betragen. Die Messzykluszeit muss dementsprechend klein sein und in einem sinnvollen Verhältnis zur Aktivierungszeit t_{sc} stehen.

Für eine genügend akkurate Schätzung bezüglich der Objektidentität, der Objektposition, der Bewegungsrichtung und der relativen Geschwindigkeit benötigt ein Tracking-Algorithmus im Durchschnitt 3 bis 4 Messzyklen. Unter Beachtung dieser Anzahl von Zyklen, der maximalen Reichweite eines Sensors und der benötigten Aktivierungszeit muss eine rechtzeitige Auslösung sichergestellt sein.

Weiterhin ist zu betrachten, ob die Abtastungen in einem festen oder einem variablen Zeitraster erfolgen. Feste Zeitraster ermöglichen eine sicherere Abschätzung der benötigten Sensorparameter und sind daher zu bevorzugen.

Reichweite Die Anforderungen bezüglich der maximalen Reichweite hängen von speziellen Anforderungen der Anwendung selber, von der Aktivierungszeit, der maximal möglichen bzw. noch berücksichtigten Relativgeschwindigkeit und der Messzykluszeit ab.

Die maximale Entfernung r_{max} , in der typische Objekte noch detektierbar sein müssen, ist folgendermaßen aus der maximalen Relativgeschwindigkeit $v_{rel,max}$ bei der gegebenen Messzykluszeit t_z , der gegebenen Aktivierungszeit t_{sc} und der Anzahl der benötigten Messzyklen n_c zu berechnen, um eine ausreichend exakte Objektinformation zu erhalten:

$$r_{max} = v_{rel,max} \cdot (t_{sc} + n_c \cdot t_z) \quad (1.5)$$

$$= v_{rel,max} \cdot ((t_a + t_o) + n_c \cdot t_z). \quad (1.6)$$

Der kleinste, noch zu detektierende Abstand berechnet sich aus

$$r_{min} = v_{rel,min} \cdot t_{sc}, \quad (1.7)$$

mit $v_{rel,min}$ als kleinster noch zu betrachtender Relativgeschwindigkeit.

Für eine Messzykluszeit t_z von 40 ms (25 Hz), eine Aktivierungszeit t_{sc} von 300 ms, angenommene 4 Messzyklen als notwendige Beobachtungszeit und eine maximalen Relativgeschwindigkeit von 150 km/h ergibt sich nach Gleichung 1.5 eine Mindestanforderung für die maximale Reichweite r_{max} eines Sensors von ca. 19,2 m. Die kleinste noch zu detektierende Entfernung r_{min} , bestimmt durch die kleinste betrachtete Relativgeschwindigkeit $v_{rel,min}$ von 20 km/h und für eine Aktivierungszeit t_{sc} von 100 ms, beträgt nach Gleichung 1.7 ca. 1,11 m.

Öffnungswinkel Um eine robuste Detektionsleistung und eine große Abdeckung der verschiedenen (Unfall-)Szenarien zu erreichen, sollte der Öffnungswinkel so groß wie möglich sein. Mit anderen Worten: Der Sichtbereich sollte in einem möglichst kurzen Abstand vom Fahrzeug (spätestens ab dem minimalen Detektionsabstand r_{min}) schon die volle Breite des Fahrzeugs abdecken.

Zuverlässigkeit Die Sensorik muss den Anforderungen der automobilen Umgebung genügen. Das bedeutet unter anderem den Betrieb unter schwierigen Wetterbedingungen (Temperatur, Niederschlag), möglichst geringe Beeinträchtigung der Detektionsleistung durch Verschmutzung, die Unempfindlichkeit gegenüber mechanischen Beanspruchungen wie Erschütterungen und ausreichende elektrische Störfestigkeit.

Mehrfachverwendung Das Sensorsystem sollte sich für verschiedene Anwendungen eignen [Mor00], um Kosten und Einbauplatz zu sparen.

Verfügbarkeit Die Sensoren müssen in ausreichender Stückzahl verfügbar sein.

Rechtliche Anforderungen Ein weiterer wichtiger Punkt ist die Einhaltung von Sicherheitsvorschriften bzw. die Möglichkeit des legalen Betriebs der Sensorik (z. B. Augensicherheit bei Lasersensoren oder Frequenzzulassung von Radarsensoren).

Als mögliche Sensortypen, die all diese Anforderungen erfüllen, kommen in erster Linie optische Sensoren und Radarsensoren in Frage. Es gibt viele in der Literatur beschriebene Anwendungen im Bereich der Umfelderkennung, die diese Sensortypen verwenden; als Beispiel seien hier [SMBD02] und [KMR02] genannt. Die Auswahl der jeweiligen Sensortypen ist jedoch entsprechend der in diesem Abschnitt dargestellten Anforderungen spezifisch auf die jeweiligen Anwendung(en) ausgerichtet.

Typische Vertreter optischer Sensoren sind Kameras. Sie kommen zum Beispiel bei Ansätzen wie „autonomes Fahren“ [Bec02, SHRE00] oder „Adaptive Cruise Control“ [GFL01] zur Fahrspurerkennung und zur robusteren Objektdetektion zum Einsatz. Ein weiteres Anwendungsfeld von Kameras ist die Klassifikation von Objekten. Kameras bieten jedoch keine direkte Abstandsinformation, was für bestimmte Anwendungen wie beispielsweise das hier vorgestellte PreCrash-System von Nachteil ist. Andere optische Sensoren, basierend auf (Laser-)Entfernungsmessung wie zum Beispiel Laserscanner, liefern bereits eine Entfernungsinformation und bei genügend hoher Winkelauflösung auch eine Kontur der Objekte bzw. eine vereinfachte Möglichkeit, unterschiedliche Objekte voneinander zu trennen. Optische Sensoren unterliegen jedoch Einschränkungen durch Wettereinflüsse. Radarsensoren sind diesbezüglich unempfindlicher und bieten oft Abstands- und Winkelinformationen, können aber in der Regel keine Konturinformationen bereitstellen.

In dem hier beschriebenen PreCrash-System kommen zwei Nahbereichsradare und ein Laserscanner zum Einsatz, da sie das Potential besitzen, die beschriebenen Anforderungen vor allem im Verbund zu erfüllen.

Das nachfolgende Kapitel 2 enthält neben der Spezifikation dieser verwendeten Sensoren auch eine kurze Beschreibung der physikalischen Eigenschaften und der meist bei diesen Sensortypen genutzten Messverfahren.

1.5 PreCrash - Logischer Systemaufbau

Eine Variante für den logischen Aufbau des PreCrash-Systems ist in Abbildung 1.4 dargestellt. Die Daten der verschiedenen Sensoren werden in Abhängigkeit von der verwendeten Fusionsarchitektur vor der heterogenen Fusion mehr oder weniger stark verarbeitet. Derartige




Abbildung 1.4: Logische Struktur des Gesamtsystems

Vorverarbeitungsschritte können zum Beispiel die Segmentierung (Zuordnung der Messpunkte des Laserscanners zu realen Objekten), das Herausfiltern von Rauschen oder das Verfolgen und Glätten der Daten (Tracking) beinhalten. Eine weitere Möglichkeit für einen Vorverarbeitungsschritt stellt die Verknüpfung von Sensordaten eines Sensortyps (zum Beispiel Nahbereichsradare) dar.

Der eigentliche Fusionsschritt ordnet die Daten der verschiedenen Sensoren einander zu und verknüpft diese entsprechend des Fusionsverfahrens. Hierbei erfolgt die Transformation der (Positions-)Daten aus den jeweiligen Sensorkoordinatensystemen in das Fahrzeugkoordinatensystem und, bei Bedarf, eine zeitliche Synchronisierung der Messungen.

Ein nachfolgender Schritt extrahiert die für die Anwendung relevanten Informationen aus den fusionierten und verarbeiteten Daten. Ein eng damit verknüpfter letzter Schritt ist die Risikoabschätzungs- bzw. Entscheidungsstufe. Diese schätzt unter Einsatz verschiedener Filterstrategien die Kollisionswahrscheinlichkeit für die einzelnen Objekte und aktiviert bei Bedarf die Aktuatorik zur passenden Zeit.

Eine etwaige Sensorausfall-Erkennung ist parallel zu dieser Systematik angeordnet. Sie schätzt die Qualität der von der Sensorik gelieferten Daten und bestimmt damit unter anderem die Gewichtung der jeweiligen Sensordaten bei Fusion und Entscheidung.

2 Beschreibung der Sensorik

2.1 Mechanischer Aufbau des Systems

Der mechanische Aufbau des Systems ist in Abbildung 2.1 dargestellt. Die Sensorik besteht aus zwei Nahbereichsradaren und einem Laserscanner, welche im Frontbereich eines Versuchsfahrzeugs befestigt sind. Die Radare liefern Abstände, Relativgeschwindigkeiten und Angaben zur Winkellage. Sie sind per CAN-Bus mit den Rechnern verbunden. Die Messwerte des Laserscanners bestehen aus Entfernungsinformationen pro Winkelschritt innerhalb eines bestimmten Öffnungswinkels und den zugehörigen Amplitudenwerten. Hier kommt eine ARCNet-Verbindung zum Übermitteln der Daten zum Einsatz.

Ein Echtzeitsystem liest die Daten der Sensoren ein und verarbeitet sie. Dieses Echtzeitsystem besteht aus zwei Prozessorkarten. Eine Prozessorkarte übernimmt die gesamte CAN-Bus-Kommunikation. Die andere Karte liest zum einen die ARCNet-Daten ein und bildet zum anderen die Basis für die gesamte Signalverarbeitung.




Abbildung 2.1: Testumgebung

Ein zweites Rechnersystem, per Ethernet mit dem Echtzeit-Rechnersystem verbunden, dient der Bedienung des Gesamtsystems. Zudem zeigt es die Ausgaben der Signalverarbeitung an. Eine an das Echtzeit-Rechnersystem angeschlossene Aktuatorik (wie etwa reversible Gurtstraffer) kann im Falle einer erkannten Unfallsituation zu Vorführzwecken ausgelöst werden.

Eine an das zweite Rechnersystem angeschlossene Kamera dient der Dokumentation bei der Speicherung von Messwerten und anschließender „Offline“-Verarbeitung.

2.2 Radar

2.2.1 Funktionsweise

Radarsensoren senden elektromagnetische Wellen aus und empfangen diese Wellen nach der Wechselwirkung mit dem jeweiligen Radarziel mit einem entfernungsabhängigen Zeitversatz wieder. Je nach Messverfahren sind Aussagen über:

- Zielentfernung,
- Zielrichtung,
- Bewegungszustand des Ziels,
- Zielklassifizierung,
- Zielidentifizierung,
- und die Zielabbildung

möglich. Bei Radarprinzipien wird zwischen monostatischem und bistatischem Aufbau unterschieden. Bei einem monostatischen Aufbau befinden sich Sender und Empfänger am selben Ort während beim bistatischen Aufbau Sender und Empfänger örtlich getrennt sind. Die Radartypen lassen sich in Primärradar mit nichtkooperativen, passiven Zielen und Sekundärradar, mit kooperativen (kommunizierenden) Zielen unterscheiden.

Auf weitere Einzelheiten zum Aufbau eines Radars soll hier nicht eingegangen werden; weiterführende Literatur ist zum Beispiel unter [Sko70], [Sko00] oder [Lud02] zu finden.

2.2.2 Randbedingungen

Im Folgenden sind einige wichtige in [Hud02] beschriebene Randbedingungen für den Betrieb von Radarsensoren zusammengefasst. Diese Randbedingungen werden sowohl von physikalischen Gesetzmäßigkeiten als auch von den verwendeten Messverfahren bestimmt. Sie prägen die sensortypischen Eigenschaften der Radarsensoren während des praktischen Einsatzes für ein Umfeld erfassungssystem. Insbesondere beeinflussen sie die Fähigkeit eines Sensors, ein Objekt unter gewissen Umgebungsbedingungen, zu denen natürlich auch die Objekteigenschaften gehören, detektieren zu können.

Physikalische Randbedingungen

Für den Fall, dass ein Sender S die Leistung P_S isotrop abstrahlt, gilt für die Leistungsdichte $S(r)$ im Abstand r :

$$S(r) = \frac{P_S}{4\pi r^2}. \quad (2.1)$$

Die Sendeantenne ist meist kein Kugelstrahler, sondern strahlt ihre Sendeleistung in eine bestimmte Raumrichtung ab. Die Leistungsdichte ist deshalb in Hauptstrahlrichtung um einen Faktor größer, auch als Antennengewinn G_S bezeichnet. Nach der isotropen Reflexion an einem Ziel mit der elektrisch wirksamen Zielfläche A_Z und dem Abstand r_1 vom Radargerät ergibt sich als Eholeistungsdichte im Abstand r_2 vom Radarziel:

$$S_r(r) = \frac{P_S}{4\pi r_1^2} \cdot G_S \cdot \frac{1}{4\pi r_2^2} \cdot A_Z G_Z. \quad (2.2)$$

Hierbei ist G_Z der Faktor, der durch Verluste oder winkelabhängige Reflexion am Radarziel mit eingerechnet werden muss. Das Produkt

$$\sigma_R = A_Z \cdot G_Z \quad (2.3)$$

wird als Radarquerschnitt (auch Rückstreuquerschnitt, -fläche, Rückstrahlquerschnitt oder -fläche) bezeichnet und besitzt die Einheit m^2 . Der Radarquerschnitt σ_R hängt von folgenden Faktoren ab:

- Zielgeometrie
- Oberflächenstruktur des Radarziels
- Wellenlänge
- Einfalls- und Ausfallswinkel der elektromagnetischen Welle

Für die Eholeistungsdichte $S_r(r_1)$ am Ort der Empfangsantenne und dem Abstand r_1 zum Radarziel gilt für ein monostatisches Radar:

$$S_r(r_1) = \frac{P_S G_S}{4\pi r_1^2} \cdot \frac{\sigma_R}{4\pi r_1^2}. \quad (2.4)$$

Die Empfangsantenne hat die elektrisch wirksame Fläche A . Dabei gilt bei einer verlustfreien Antenne mit einem Gewinn G :

$$A = \frac{\lambda^2}{4\pi} \cdot G. \quad (2.5)$$

Für die Empfangsleistung

$$P_E = S_r(r_1) \cdot A_Z \quad (2.6)$$

gilt mit dem Gewinn G_E der Empfangsantenne:

$$P_E = P_S \cdot \frac{\lambda^2}{(4\pi)^3 r_1^4} \cdot G_S G_E \cdot \sigma \quad (2.7)$$

bzw. bei einem Einantennengerät mit $A_E = A_S = A$ und $G_E = G_S = G$:

$$P_E = P_S \cdot \frac{G^2 \lambda^2}{(4\pi)^3 r_1^4} \cdot \sigma. \quad (2.8)$$

Die Gleichungen 2.7 und 2.8 werden als Radargleichungen für das monostatische Radarverfahren bezeichnet (Sonderfall Einantennengerät Gl. 2.8).

Bei Einbeziehung der Ausbreitungsdämpfung a (in dB/km) der Atmosphäre ist die Gleichung 2.8 folgendermaßen zu ergänzen:

$$P_E = P_S \cdot \frac{G^2 \lambda^2}{(4\pi)^3 r_1^4} \cdot \sigma \cdot 10^{-\frac{a}{10} \cdot 2r_1}. \quad (2.9)$$

Das Ausbreitungsverhalten elektromagnetischer Wellen hängt neben der Frequenz auch von den atmosphärischen Gegebenheiten ab. So spielen neben Brechung und Beugung auch Ausbreitungsanomalien, wie extrem dämpfungsarme Luftschichten, eine Rolle. Ab ca. 1 GHz ist jedoch der Einfluss der Beugung sehr gering. Aufgrund des unterschiedlichen Brechungsindex verschiedener Luftschichten kann es zur Krümmung der Strahlung kommen.

Messverfahren

Als mögliches Messverfahren soll hier ausschließlich das bei der geforderten Anwendung meist verwendete Prinzip des Pulsradars betrachtet werden.

Das Pulsradargerät strahlt ein pulsmoduliertes, hochfrequentes Trägersignal ab – im einfachsten Fall durch Ein- und Ausschalten des Senders. Die Parameter eines Pulsradars sind dabei:

- die Pulsdauer bzw. Impulsdauer τ_P ,
- die Pulsperiodendauer T ,
- die Pulsfrequenz $f_p = 1/T$,
- und das Tastverhältnis τ_P/T

des pulsmodulierten Signals. Für die Impulslaufzeit δt bei der Zielentfernung r und der Ausbreitungsgeschwindigkeit c_r gilt:

$$\Delta t = \frac{2r}{c_r}. \quad (2.10)$$

Die Wahl der Systemparameter bestimmt die Eigenschaften des Pulsradargeräts.

Die Wahl der Sendefrequenz wird von den Geräteeigenschaften begrenzt. Die untere Grenze bestimmen meist:

- realisierbarer Antennengewinn bzw. realisierbare Antennenhalbwertsbreite (3-dB-Breite) bei gegebenen Antennenabmessungen,
- Ausbreitungseigenschaften elektromagnetischer Wellen bei niedrigen Frequenzen und
- Beeinflussung der Messgenauigkeit durch Fremdstörer.

Bei hohen Frequenzen wirken sich jedoch begrenzend aus:

- mit wachsender Frequenz geringer werdende Sendeleistung,

- ansteigende Ausbreitungsdämpfung in der Atmosphäre (siehe Bild 2.6) und
- zunehmende Gerätekosten aufgrund der notwendigen Präzision von Höchstfrequenzbauelementen und -schaltungen.

Die Sendefrequenz bestimmt die absolut untere Grenze der Pulsdauer:

$$\tau_p \gg T_S = \frac{1}{f_S}. \quad (2.11)$$

Die Pulsdauer muss wegen der Einschwing- und Ausschwingzeit des Senders wesentlich größer als die Periodendauer des Sendesignals sein, damit ein Impuls zumindest einige vollständige Schwingungen der Sendefrequenz f_S enthält. Die maximale obere Grenze der Pulsdauer wird durch die minimale Entfernungsauflösung bestimmt. Eine Auflösung zwischen zwei Zielen ist nur gegeben, wenn gilt:

$$2\Delta r - \tau_P c_r > 0. \quad (2.12)$$

Dabei ist Δr der Abstand zwischen zwei Zielen, τ_0 die Breite des Pulses und c_r die Ausbreitungsgeschwindigkeit. Der Grenzfall Δr_{min} errechnet sich so aus:

$$\Delta r_{min} = \frac{1}{2} \cdot \tau_P c_r. \quad (2.13)$$

Die mittlere Sendeleistung

$$\bar{P}_S = \frac{1}{T} \cdot \int_0^T P(t) dt = \hat{P}_S \cdot \frac{\tau_P}{T} \quad (2.14)$$

sollte so niedrig wie möglich gewählt werden, um Verlustleistung und gerätetechnischen Aufwand für Stromversorgung und eine eventuell notwendige Kühlung des Senders in Grenzen zu halten. Aufgrund dessen ist das Tastverhältnis τ_P/T klein zu halten.

Ein weiterer Aspekt ist die Signalbandbreite. Es liegt ein bei der Frequenz Null beginnendes, periodisches Linienspektrum vor. Der Abstand der einzelnen Spektrallinien ist $\Delta f = 1/T = f_P$. Bei ideal rechteckförmigen Pulsen der Dauer τ_P weist das Linienspektrum eine Einhüllende nach der Funktion $\sin(x)/x$ auf, deren Nullstellen bei den Frequenzen n/τ_P mit $n = 1,2,3...$ liegen. Für die praktisch belegte Bandbreite des Signals gilt hier:

$$B_S \approx \frac{1}{\tau_P}. \quad (2.15)$$

Bei der Wahl der Pulsfolgefrequenz ist darauf zu achten, dass der Bereich zwischen Radargerät und Ziel eindeutig bestimmbar ist. Die eindeutige Reichweite r_{ein} muss sinnvollerweise mindestens auf die maximale Reichweite r_{max} des Pulsradars festgelegt sein. Damit ist dann

$$r_{ein} = r_{max} = \frac{1}{2} \cdot c_r \Delta t_{max} \quad (2.16)$$

$$\Delta t_{max} = T - T_{Tot}, \quad (2.17)$$

wobei T die Pulsperiodendauer und T_{Tot} die Zeit ist, die innerhalb der Pulsperiodendauer nicht als Laufzeit verwendet werden kann.

Eigenschaften im praktischen Einsatz

Im Folgenden sind einige Eigenschaften des Radars (zum Teil speziell der hier verwendeten Radar-Prototypen) im praktischen Einsatz kurz aufgeführt.

Wetter Wie in Abbildung 2.6 ersichtlich, haben Wetterbedingungen wie Regen, Schnee oder Nebel nur geringen Einfluss auf die Messung.

Störeinflüsse durch mehrere Sensoren gleichen Typs Bei Betrieb mehrerer Radarsensoren gleichen Typs innerhalb deren Reichweite kann es, abhängig von den verwendeten Messverfahren, zu gegenseitigen, direkten oder indirekten (vom Ziel reflektierte Impulse eines anderen Radars) Störungen und damit zu falschen Messergebnissen kommen (Bild 2.2). Diese Störungen sind im Falle unsynchronisierter Sensoren zufällig verteilt und können dann




Abbildung 2.2: Störungen (einzelne Punkte) in den Abstandsmessungen von 4 Sensoren bei Vorbeifahrt an Objekten (Linien)

recht einfach bei der Signalverarbeitung unterdrückt werden. Eine weitere Möglichkeit der Abhilfe besteht in der Wiederholung der Messungen mit verschiedenen Pulsfolgefrequenzen.

Reflexion Ab einem bestimmten Einfallswinkel auf eine glatte Oberfläche wie die eines Autos wird der einfallende Radarimpuls weggespiegelt (Totalreflexion). Teile eines solchen Zieles bleiben für diesen Sensor damit praktisch „unsichtbar“.

Überreichweite Die Wahl der Pulsfolgefrequenz bestimmt die Anfälligkeit der Radare bezüglich Überreichweite. Ein Problem dabei ist, dass der Rückstreuquerschnitt A_Z bei unterschiedlichen Zielen große Abweichungen aufweist. Dies führt in einigen Fällen zu einer falschen

Entfernungsbestimmung eines Zieles, wenn die zurückreflektierte Signalstärke so groß ist, dass das Signal auch noch im nächsten Messfenster detektiert wird. Abhilfe kann hier die Wahl einer niedrigen Pulsfolgefrequenz oder das Ändern der Pulsfolgefrequenz bei Wiederholung derselben Messung schaffen. Bei der Änderung der Pulsfolgefrequenz während wiederholter Messungen sind dann die Ziele auszufiltern, die bei den unterschiedlichen Messungen nicht zu denselben Ergebnissen führen.

Mehrfachreflexion Signale, die nicht direkt von der Sendeantenne zum Ziel und zurück zur Empfangsantenne laufen, sondern über mehrere Ziele hinweg zur Empfangsantenne reflektiert werden, führen zu Fehlmessungen.

Mechanik Aufgrund der Tatsache, dass sich in einem Radargerät für Anwendungen im Automobilbereich keine beweglichen Bauteile befinden, sind solche Sensoren kaum anfällig gegenüber Erschütterungen.

Einbau Wegen relativ geringer Abmessungen der Nahbereichsradare ist die Anbringung innerhalb der Fahrzeugstoßstangen meist ohne Eingriffe in das Fahrzeugdesign möglich.

2.2.3 Spezifikation der verwendeten Sensoren

Für die Realisierung des PreCrash-Systems kamen zwei verschiedene Typen von Nahbereichsradaren zum Einsatz. Beide Radartypen besitzen einen Öffnungswinkel von ca. 60° bei einer Reichweite von etwa 30 m. Sie liefern Angaben zur Entfernung und Relativgeschwindigkeit der detektierten Ziele. Die Entfernungsauflösung der Sensoren beträgt 15 cm. Die Unterschiede zwischen den Sensoren bestehen in der zusätzlichen Bereitstellung von Winkelinformation durch einen Sensortyp [HKF05]. Die Genauigkeit der Winkelangabe nimmt, beginnend von der Mittelachse, mit größeren Winkeln kontinuierlich ab, bis hin zu fehlender Winkelinformation im Seitenbereich. Beide Sensortypen befanden sich zum Zeitpunkt der Messungen in einem fortgeschrittenen Prototypenstatus.

2.3 Laserscanner

2.3.1 Aufbau und Funktionsweise

Laserscanner sind optische Sensoren, die Abstände in einem gewissen Bereich horizontaler und vertikaler Öffnungswinkel messen. Eine weitere Messgröße stellt auch der Reemissionswert (Rückstrahlintensität) dar. Als Strahlenquelle wird eine Laserdiode verwendet, wobei die Wellenlänge zumeist um die 900 nm beträgt.

In Bild 2.3 ist der prinzipielle Aufbau eines Laserscanners dargestellt.

Zur Funktionsweise: Der von der Laserdiode ❶ ausgesendete Laserimpuls durchdringt den halbdurchlässigen Spiegel ❸ und trifft auf den beweglichen Spiegel ❹. Dieser lenkt den Strahl durch eine bündelnde Optik in eine bestimmte Raumrichtung ab. Sobald der Strahl auf eine reflektierende Oberfläche ❺ trifft, wird er von dieser (meist diffus) reflektiert. Der bewegliche Spiegel reflektiert den zurückkommenden Strahl auf den halbdurchlässigen Spiegel, welcher ihn in Richtung Empfangsdiode ❷ ablenkt. Mit Hilfe von z. B. Laufzeitmessung oder Messung




Abbildung 2.3: Aufbau eines Laserscanners

der Phasenverschiebung (relativ zum ausgesendeten Signal) ist die Entfernung des reflektierenden Objekts bestimmbar. Als weitere Information steht die empfangene Intensität des reflektierten Signals (Reemissionswert) zur Verfügung. Dieser Vorgang wiederholt sich für alle einstellbaren Spiegelstellungen mit einer bestimmten Schrittweite bzw. Winkelauflösung. Das Resultat ist eine linienförmige, eindimensionale Entfernungsverteilung der Umgebung in einem vorgegebenen Winkelbereich (siehe Bild 2.4).




Abbildung 2.4: Messwerte eines Laserscanners (4 Ebenen)

2.3.2 Randbedingungen

Die folgenden Abschnitte beinhalten einen Überblick zu den physikalischen Gesetzmäßigkeiten und Messverfahren, die den Sensortyp Laserscanner in seinen Eigenschaften – insbeson-

dere der Fähigkeiten hinsichtlich der Objektdetektion – maßgeblich beeinflussen.

Physikalische Randbedingungen

Laserstrahlung ist ein Spezialfall elektromagnetischer Wellen und wird im einfachsten Fall durch die in z -Richtung laufende harmonische Welle

$$\vec{E} = \vec{E}_0 \cdot \cos(\omega t - kz - \phi_0) \quad (2.18)$$

$$\vec{H} = \vec{H}_0 \cdot \cos(\omega t - kz - \phi_0) \quad (2.19)$$

beschrieben [DN93]. Dabei ist \vec{E} die elektrische Feldstärke, \vec{H} die magnetische Feldstärke, \vec{E}_0 bzw. \vec{H}_0 die Amplitude, ω die Kreisfrequenz, k die Wellenzahl und ϕ_0 der Phasenwinkel. Die elektrische Feldstärke \vec{E} , die magnetische Feldstärke \vec{H} und die Ausbreitungsrichtung z stehen jeweils senkrecht aufeinander.

Zwischen der Kreisfrequenz ω , der Wellenzahl k , der Wellenlänge λ und der Frequenz f bestehen weiterhin die Zusammenhänge:

$$\omega = 2\pi f \quad (2.20)$$

$$k = \frac{2\pi}{\lambda}. \quad (2.21)$$

Die Phasengeschwindigkeit c der elektromagnetischen Welle in einem homogenen und verlustfreien Medium beträgt:

$$c = \frac{\omega}{k} \quad (2.22)$$

$$= \frac{c_0}{n_S} \quad (2.23)$$

$$= f\lambda. \quad (2.24)$$

Hierbei ist c_0 ($c_0 \approx 3 \cdot 10^8 \frac{m}{s}$) die Lichtgeschwindigkeit im Vakuum und n_S der Brechungsindex des Mediums.

Mit der Betrachtung des Lichtes als elektromagnetische Welle lassen sich eine Anzahl von Eigenschaften wie z. B. Beugung oder Interferenz erklären. Für die Deutung der Wechselwirkung des Lichtes mit Materie muss aber zusätzlich der Teilchencharakter des Lichtes berücksichtigt werden. Danach besteht Licht aus Teilchen, den Photonen, die sich mit Lichtgeschwindigkeit bewegen. Die Energie, die einem Photon zugeordnet wird, ist proportional der Frequenz f :

$$W = hf. \quad (2.25)$$

Der Proportionalitätsfaktor, das **Plancksche Wirkungsquantum**, beträgt $h \approx 6,6 \cdot 10^{-34} Js$. Ein Photon besitzt neben der Energie auch den Impuls

$$p = \frac{hf}{c_0}. \quad (2.26)$$

Gleichung 2.23 zeigt die Phasengeschwindigkeit des Lichtes in einem dielektrischen Medium. Die Brechungsindizes n_S durchsichtiger Stoffe nehmen typischerweise Werte zwischen $1 < n_S < 3$ an. Damit liegen die Phasengeschwindigkeiten in der Regel unter der Vakuumlichtgeschwindigkeit c_0 . Der Brechungsindex n_S hängt von der Wellenlänge λ bzw. der Frequenz f ab. Dies wird als Dispersion bezeichnet und hängt eng mit der Absorption zusammen. Allgemein gilt, dass eine Absorptionslinie (Absorptionskoeffizient α) mit der Änderung des Brechungsindex (und damit auch der Wellenlänge) einhergeht. Bei Lichteinfall auf Grenzflächen zwischen zwei verschiedenen Dielektrika tritt eine teilweise Reflexion auf. Der durchgelassene Strahl wird gebrochen:

$$n_1 \sin \Theta_{E1} = n_2 \sin \Theta_{E2}. \quad (2.27)$$

Die Winkel Θ_{E1} und Θ_{E2} sind Einfallswinkel bzw. Winkel nach dem Übergang und auf das Lot zur Grenzfläche bezogen. Der Reflexionsgrad R beschreibt das Verhältnis der Intensitäten von einfallendem und reflektiertem Strahl, wobei bei R_s der Vektor des elektrischen Feldes senkrecht und bei R_p parallel zur Einfallsebene steht:

$$R_s = \left(\frac{\sin(\Theta_{E1} - \Theta_{E2})}{\sin(\Theta_{E1} + \Theta_{E2})} \right)^2 \quad (2.28)$$

$$R_p = \left(\frac{\tan(\Theta_{E1} - \Theta_{E2})}{\tan(\Theta_{E1} + \Theta_{E2})} \right)^2. \quad (2.29)$$

Bei senkrechtem Einfall gilt:

$$R_s = \left(\frac{n_1 - n_2}{n_1 + n_2} \right)^2. \quad (2.30)$$

Der Grenzwinkel Θ_G der Totalreflexion

$$\sin \Theta_G = \frac{n_2}{n_1} \quad (2.31)$$

ist der Winkel, bei dessen Überschreitung der einfallende Strahl, unabhängig von der Polarisationsrichtung, vollständig reflektiert wird.

Wichtig für die Betrachtung der Eigenschaften des Lasers in Bezug auf die Anwendung sind Reflexion und Brechung an ebenen und rauen Oberflächen. Für den Fall, dass der Lichtstrahl auf eine raue Oberfläche (d. h., dass die Unebenheiten groß gegenüber der Wellenlänge sind) trifft, tritt eine diffuse Reflexion, auch als Reemission bezeichnet, auf und unabhängig vom Einfallswinkel Θ_{E1} gilt dann das *Lambertsche Kosinus-Gesetz*:

$$I = I_0 \cos \Theta_B. \quad (2.32)$$

Die Intensität I ist damit abhängig vom Beobachtungswinkel Θ_B , der wie Θ_{E1} auf die Flächennormale bezogen ist.

Neben Brechung und Reflexion spielt bei der gegebenen Anwendung die Absorption eine große Rolle. Die Lichtintensität I nimmt längs eines Weges, abhängig vom linearen Absorptionskoeffizient α , der Strecke d und der anfänglichen Lichtintensität I_0 , exponentiell ab:

$$I(d) = I_0 \cdot e^{(-\alpha d)}. \quad (2.33)$$

Im Fall, dass intensives, fokussiertes Laserlicht verwendet wird, tritt aufgrund der induzierten Emissionen von Photonen in Richtung der einfallenden Welle mit gleicher Frequenz, Polarisations- und Ausbreitungsrichtung der Effekt der Transmission in Erscheinung. Dies ist die nichtlineare Absorption. In guter Näherung lässt sich der Transmissionsgrad T_T durch die Funktion

$$T_T \approx T_0 0^{\frac{1}{1 + \frac{I_S}{I_0}}} \quad (2.34)$$

beschreiben. Dabei ist T_0 der Transmissionsgrad bei niedrigen Intensitäten im Bereich der linearen Absorption und I_S die für den Absorber typische Sättigungsintensität.

Messverfahren

Als Messverfahren kommt bei Laserscannern oft die Laufzeitmessung zum Einsatz. Hierbei wird ein Lichtimpuls ausgesendet und von dem Ziel (diffus) reflektiert. Die Zeit bis zum Wiedereintreffen des reflektierten Impulses lässt sich mittels hochpräziser Zeitmesser (z. B. TDC – *Time-to-Digital-Converter* [WMO⁺93]) bestimmen:

$$t_l = \frac{2r}{c_l}. \quad (2.35)$$

Die Laufzeit t_l ergibt sich hier aus dem zweifachen Abstand r und der Ausbreitungsgeschwindigkeit c_l . Der Abstand ist damit direkt ermittelbar. Als Vorteil dieses Verfahrens besteht die Möglichkeit, mehrere Ziele pro Messung zu erfassen. Weiterhin ist die Verwendung höherer Leistungen und damit die Erhöhung der Reichweite bei gepulsten Signalen im Gegensatz zu kontinuierlichen Verfahren in Hinsicht auf die Augensicherheit möglich.

Die Laufzeit des Pulses ist aufgrund der hohen Lichtgeschwindigkeit schwer zu messen. Eine Methode besteht darin, beim Senden des Impulses ein Signal durch einen Ring von Verzögerungsgliedern (bestehend aus z. B. 63 Gliedern) laufen zu lassen. Wie in Bild 2.5 dargestellt, existiert in diesem Ring zur Einsparung von Verzögerungsgliedern auch ein Zähler. Das Startsignal **PA** läuft durch die Reihe der Verzögerungsglieder. Nachdem das Signal alle Verzögerungsglieder durchlaufen hat, wird der Zähler invertiert und das Signal wieder zurückgeführt. Bei Eintreffen des empfangenen Pulses (Aktivierung des Stoppsignals **PB**) wandelt ein Encoder die Ausgänge der Latches in einen numerischen Wert um. Zusammen mit dem Wert des Zählers ist dieser Wert direkt proportional zur Laufzeit des Pulses.

Die Genauigkeit der Messung beeinflusst dabei:

1. die Signallaufzeit t_{lV} durch ein Verzögerungsglied (entspricht der Messauflösung) und
2. die Verschiebung t_s bei Ankunft des Empfangssignals **PB** (zusätzlich durchlaufene Verzögerungsglieder).

Eigenschaften im praktischen Einsatz

In diesem Abschnitt sind verschiedene Aspekte im praktischen Einsatz des Laserscanners aufgeführt.




Abbildung 2.5: Time-to-Digital-Converter

Wetter Als optisches System unterliegt der Laserscanner im Betrieb verschiedenen Einschränkungen. So können Regen, Schnee und Nebel die maximale Reichweite des Systems beeinflussen. Dies ist abhängig von der benutzten Wellenlänge. In Abbildung 2.6 ist die Dämpfung der elektromagnetischen Strahlung als Funktion der Wellenlänge dargestellt. Neben Schmutz beeinträchtigen auch Wasser- und Schneeablagerungen die Detektionsleistungen des Sensors. Temperaturschwankungen können durch Kondensation des in der Luft enthaltenen Wasserdampfes zum Beschlagen der Optik des Laserscanners führen.

Störeinflüsse durch mehrere Sensoren gleichen Typs Bei der Verwendung mehrerer Sensoren des gleichen Typs können direkte und indirekte gegenseitige Beeinflussungen der Sensoren auftreten. Bei Laserscannern ist eine recht unwahrscheinliche direkte Beeinflussung (Laserstrahl eines Sensors direkt in Empfangsoptik eines anderen z. B. durch ein anderes Fahrzeug) durch entsprechenden Einbau bzw. Neigungswinkel zu verhindern. Störungen durch indirekte Beeinflussung, wie etwa der Empfang eines Pulses, der von einem anderen Laserscanner ausgesendet wurde, sind ebenso wie Einflüsse durch direkte Einstrahlung sehr unwahrscheinlich und auch nur kurz andauernd (eine Messung), da der einfallende Strahl parallel zur optischen Achse des Empfängers liegen muss. Dies tritt nur auf, wenn beide Sensoren zu einem Zeitpunkt genau dieselbe Stelle abtasten, wie rechts in Abbildung 2.7 dargestellt.

Reflexion Ab einem bestimmten Einfallswinkel auf eine glatte Oberfläche wie die eines Autos wird der einfallende Lichtimpuls weggespiegelt (Totalreflexion). Teile eines solchen




Abbildung 2.6: Absorption elektromagnetischer Strahlung in der Atmosphäre [Kle99]

Zielees bleiben für den Laserscanner damit „unsichtbar“.

Mechanik Aufgrund der Tatsache, dass sich in einem Laserscanner bewegliche Teile befinden, sind solche Sensoren zu einem gewissen Grad anfällig gegenüber Erschütterungen.

Einbau Die derzeit noch große Bauform der Laserscanner schränkt die Auswahl an möglichen Einbauorten in einem PKW stark ein. Zudem sind aufgrund der Empfindlichkeit optischer Systeme gegen Verschmutzung geeignete Reinigungsvorrichtungen vorzusehen, welche das Sichtfenster frei von Verschmutzungen oder Wasser halten.

Die Abdeckung muss aus für die Wellenlänge durchlässigem Material bestehen. An der Abdeckung kann das vom Laserscanner ausgesendete Signal in Abhängigkeit vom Einstrahlwinkel reflektiert werden. Dies kann ein den maximalen Öffnungswinkel beschränkender Faktor sein, da ein tieferer Einbau (größerer Abstand zur Abdeckung) den Winkel zwischen Abdeckung und Laserstrahl vergrößert, den maximalen Öffnungswinkel bei gegebener Breite des Sichtfensters allerdings verkleinert.

2.3.3 Spezifikation des verwendeten Sensors

Der hier verwendete Laserscanner zeichnet sich durch das Vorhandensein von vier vertikal angeordneten Messebenen aus. Der Winkel zwischen zwei Messebenen beträgt $0,8^\circ$. In horizontaler Richtung spannen die Ebenen einen Bereich von bis zu 270° bei einer maximalen Winkelauflösung von $0,25^\circ$ auf, die im Rahmen der Arbeiten verwendete Auflösung beträgt 1° . Objekte mit durchschnittlichen Reflexionseigenschaften sind für den Sensor bis zu ca. 80 m bei einer auf den Abstand bezogenen Messgenauigkeit von etwa 20 cm sichtbar. Aufgrund vorhandener Einbaubeschränkungen des Versuchsfahrzeugs betrug der verwendete




Abbildung 2.7: Strahlverlauf bei unterschiedlichen Abtastpunkten (links) und indirekte Störeinstrahlung bei Laserscannern bei gleichem Abtastpunkt (rechts)

Öffnungswinkel des Sensors für die Applikation ausreichende 97° . Neben Entfernungswerten pro Winkelschritt liefert der Sensor auch die Intensitätswerte der reflektierten Pulse. Wie auch die Radarsensoren befindet sich der Laserscanner in einem fortgeschrittenen Prototypenstatus.

2.4 Gegenüberstellung der beiden Sensoren

Zusammenfassend sind hier sowohl die wichtigsten Vor- als auch die Nachteile des jeweiligen Sensortyps dargestellt, die Einfluss auf die Funktionalität des PreCrash-Systems haben. Grundlage für diese Gegenüberstellung sind praktische Erfahrungen mit Prototypen von Radarsensoren der Firma M/A-COM und einem Laserscanner Typ LD ML der Firma IBEO AS GmbH.

Vorteile und Nachteile des Nahbereichsradare

Für das Nahbereichsradar sind folgende Vorteile anzuführen:

- Wettereinflüsse auf Sensor geringer als bei Laserscanner
- Unabhängigkeit von Tageslicht
- Informationen über Relativgeschwindigkeit der detektierten Objekte (integriertes Tracking)
- Keine beweglichen Teile im Sensor und damit geringere Anfälligkeit gegenüber Erschütterungen
- Kleine Bauform

Folgende Nachteile bestehen jedoch:

- In Abhängigkeit von der Bauart keine oder ungenaue Winkelangaben

- Detektionen liegen ausschließlich als Punktziele vor
- Niedrige Entfernungsauflösung (kann bei der Bestimmung des Winkels bzw. der Verbesserung der Winkelangabe problematisch sein, siehe auch Abschnitt 4.1)
- Störeinflüsse durch Sensoren des gleichen Typs möglich
- Öffnungswinkel abhängig von Objekten im Erfassungsbereich (Rückstreuquerschnitt, vgl. Abschnitt 2.2.2)
- Kleiner Erfassungsbereich in Bezug auf Entfernung
- Totalreflexionen bei flachem Einstrahlwinkel an Objekt
- Zulassungsverfahren für legalen Betrieb notwendig
- Akzeptanzprobleme aufgrund elektromagnetischer Strahlung

Vorteile und Nachteile des Laserscanners

Der Laserscanner bietet folgende Vorteile:

- Großer Erfassungsbereich im Bezug auf Entfernung und Öffnungswinkel
- Hohe Messauflösung im Bezug auf Entfernung und Winkel (Konturen)
- Klar festgelegter Öffnungswinkel
- Höhenschätzung bzw. Ausgleich von Fahrzeugneigungen durch mehrere, übereinanderliegende Lagen
- Relativ störfest gegenüber Einflüssen von Sensoren gleichen Typs
- Unabhängigkeit von Tageslicht
- Akzeptanz eines Laserscanners bei Kunden vermutlich höher als die eines Radarsensors
- Keine Zulassungsprobleme (Augensicherheit)

Die wichtigsten Nachteile des Laserscanners sind:

- Anfälligkeit gegenüber Wettereinflüssen (Regen, Nebel, Schnee) und Verschmutzungen
- Kleiner Erfassungsbereich in vertikaler Richtung
- Totalreflexion an glatten Oberflächen bei Auftreffen in einem flachen Winkel
- Derzeit nur in großen Bauformen lieferbar
- Einsatz von Mechanik und damit anfällig gegenüber Erschütterungen
- Fehlende Geschwindigkeitsinformation

Der Einfluss der hier aufgeführten Eigenschaften beider Sensortypen in Bezug auf die Fusion der Sensordaten für ein umfelderfassendes System – speziell für ein PreCrash-System – ist unter anderem Inhalt des nachfolgenden Kapitels.

3 Grundlegende Betrachtungen zur Fusion

Dieser Abschnitt stellt neben dem Begriff *Sensordatenfusion* und den bei der Fusion verfolgten Zielen überblicksweise die grundlegenden Konzepte und Definitionen vor, auf denen Sensordatenfusionsansätze basieren bzw. nach denen sie einzuordnen sind. Es existiert eine Vielzahl von Definitionen und Einordnungsmerkmalen, die meist unterschiedliche Aspekte betonen.

Weiterhin sind einige Werkzeuge zur Sensordatenfusion beispielhaft aufgeführt. Kapitel 5 beschreibt später konkrete Werkzeuge bzw. Architekturen detaillierter, die bei der Fusion der Daten von Nahbereichsradaren und Laserscanner zum Einsatz kommen können.

Ein weiterer Teil dieses Kapitels beinhaltet die Darstellung von Vor- und Nachteilen der Sensordatenfusion – sowohl allgemein als auch auf die verwendeten Sensorsysteme bezogen. Die genannten Vorteile stellen gleichzeitig die Motivation für die Fusion von Laserscanner und Nahbereichsradaren für ein PreCrash-System dar.

3.1 Sensordatenfusion

3.1.1 Begriffsdefinitionen

In der wissenschaftlichen Literatur existieren viele Definitionen des Begriffes *Sensordatenfusion*. Eine der Definitionen für den Begriff *Sensordatenfusion* lautet:

Data fusion is a formal framework in which are expressed the means and tools for the alliance of data originating from different sources. It aims at obtaining information of greater quality; the exact definition of 'greater quality' will depend upon the application.[Wal98]

Diese recht allgemein gehaltene Definition ist angesichts der Vielzahl an vorhandenen Techniken, Hilfsmitteln und auch aufgrund der Vielzahl an möglichen Klassifikationen von Fusions-typen gut geeignet. Insbesondere setzt diese Definition keine Techniken oder Architekturen voraus.

Eine weitere Definition lautet: *This field of technology has been appropriately termed data fusion because the objective of its processes is to combine elements of raw data from different sources into a single set of meaningful information that is of greater benefit than the sum of its contributing parts.*[WL90]

Die Betonung bei dieser Definition liegt vor allem auf dem Gewinn bzw. Synergieeffekt, der durch die geeignete Verknüpfung von Daten unterschiedlicher Quellen entsteht.

In den nachfolgenden Abschnitten sind unter anderem einige mögliche und für die nachfolgenden Kapitel wichtigen Unterscheidungskriterien für Arten der Fusion aufgeführt.

3.1.2 Ziele und Potential von Sensordatenfusionsansätzen

Ziel ist die Gewinnung von Umweltdaten mit dem Anspruch auf Vollständigkeit, Genauigkeit, Sicherheit und Widerspruchsfreiheit. Bei Verwendung der Sensordatenfusion ist die Erreichung dieser Ziele potentiell wahrscheinlicher als ohne:

Reale Sensoren erfassen immer nur räumlich begrenzte Bereiche, liefern ungenaue Daten und sind in einem gewissen Maße unzuverlässig. Zudem benötigen sie eine bestimmte Dauer zur Erfassung eines Phänomens und zur Bereitstellung der Daten am Ausgang. Die Kombination von Sensoren hilft, negative Effekte, die aus den Eigenschaften realer Sensoren herrühren, zu minimieren. Die wichtigsten Punkte sind [Bec02, BI97, WL90]:

Zuverlässigkeit Zusätzliche Sensorik führt zu Redundanz, die das System robuster gegenüber Ausfällen einzelner Sensoren und Umwelteinflüssen macht. Die geschickte Kombination verschiedener Sensortypen ermöglicht den Ausgleich von Schwachstellen einzelner Sensortypen.

Detektionswahrscheinlichkeit Die Redundanz von Sensorik erhöht die Detektionswahrscheinlichkeit und damit die Verlässlichkeit des Gesamtsystems.

Genauigkeit Durch die Verwendung von Sensoren, deren Messfehler nicht korreliert sind, lässt sich die Genauigkeit von Schätzungen erhöhen.

Sichtbereich Die räumlichen Erfassungsbereiche der Sensoren überlappen sich oft nur teilweise oder gar nicht und bilden gemeinsam einen größeren Erfassungsbereich als ein einzelner Sensor.

Mehrdeutigkeiten Bei der Verwendung von Einzelsensorik oft auftretende Mehrdeutigkeiten sind durch die Nutzung von Daten zusätzlicher Sensorik auflösbar.

Zusätzliche Informationen Die (kombinierten) Daten unterschiedlicher Messverfahren erweitern das Wissen über den beobachteten Bereich.

Messraten Sensoren, die gleiche Phänomene zu unterschiedlichen Zeiten messen, erhöhen damit effektiv die Messrate.

Kosten Ein wichtiges Ziel bei der Fusion mehrerer Sensoren ist oft die Reduktion der Kosten für das Gesamtsystem. Der (bezogen auf die Erkennungsleistungen gleichwertige) Ersatz eines teuren einzelnen Sensors durch mehrere günstige Sensoren ist eine Vorgehensweise, die die Kosten des Gesamtsystems deutlich verringern kann.

3.1.3 Nachteile der Sensordatenfusion

Die Fusion von Daten verschiedener Sensoren hat natürlich nicht nur Vorteile. Die Einbeziehung der Daten mehrerer Sensoren führt in der Regel zu höheren Datenraten und einer

zunehmenden Komplexität des Gesamtsystems. Gerade die steigende Komplexität ist eine Ursache für eine wachsende Anzahl von Fehlern bei Spezifikation und Implementation. Hohe Datenraten verursachen höhere Kosten bzw. größeren Zeitaufwand bei der Verarbeitung. Die Verwendung mehrerer Sensoren verursacht immer höheren Aufwand bei der Integration der Sensorik und der Versorgungseinrichtungen. Die Kosten für die Sensorik steigen auch, wenn nicht mehrere günstige Sensoren einen teuren Sensor ersetzen sollen. Ein weiteres, von der Wahl der verschiedenen Sensoren oft unabhängiges Problem ist die zeitliche Abfolge der Messungen der unterschiedlichen Sensoren. Die Sensoren erfassen die Umgebung sehr oft zu unterschiedlichen Zeiten. Der Nachteil besteht in der Notwendigkeit der Synchronisation der Daten, die durch die Fusion oft nicht „per Hardware“ synchronisierbarer Sensoren entsteht.

3.1.4 Unterscheidungskriterien

Unterscheidung nach Funktionalität

In Abhängigkeit der Funktionalität des Multisensorsystems bzw. der fusionierten Sensoren in ihrem Zusammenspiel besteht die Möglichkeit der Unterscheidung nach vier Fusionsarten [BI97]:

Komplementäre Fusion Bei der Fusion voneinander unabhängiger Sensoren, die mit dem Ziel der Gewinnung vollständigerer Daten unterschiedliche Bereiche oder Phänomene betrachten, findet eine *komplementäre Fusion* statt. So können zum Beispiel verschiedene Sensoren bei einer „räumlich“ komplementären Fusion unterschiedliche Sichtfelder abdecken oder bei einer „zeitlich“ komplementären Fusion zu unterschiedlichen Zeitpunkten messen.

Konkurrierende Fusion Bei Erfassung der gleichen Umweltinformationen in einem gemeinsamen Sichtbereich durch mehrere Messungen entsteht eine Konkurrenz zwischen den Messwerten. Ziel der *konkurrierenden Fusion* ist das Vereinheitlichen der Informationen zu einer, die dem realen Wert am nächsten kommt. Hierbei erfolgt eine Reduzierung der Redundanz. Ein einfaches Beispiel ist die Zusammenführung von Messwerten unterschiedlicher Sensoren durch ein Fusionssystem mit Hilfe (gewichteter) Mittelung.

Kooperative Fusion Oft erbringen einzelne Sensoren eine benötigte Information nicht allein. Die Gewinnung der Information durch Zusammensetzen (Kombination) der Messwerte verschiedener Sensoren stellt eine *kooperative Fusion* dar. Das Fusionieren von Daten mehrerer abstandsmessender Sensoren zur Bestimmung einer Objektposition ist ein Beispiel für einen solchen Fusionsansatz.

Unabhängige Fusion Diese Art der Fusion beinhaltet das Verarbeiten von Messungen unterschiedlicher Sensoren, das jedoch nicht den vorher genannten Fusionsarten entspricht. Sie stellt im strengen Sinn keine Sensordatenfusion dar, kommt aber in der Praxis durch die Verarbeitung von Daten verschiedener Sensoren in einem gemeinsamen System, jedoch ohne direkte Verknüpfung, häufig vor.

3 Grundlegende Betrachtungen zur Fusion

Oft finden in realen Systemen Kombinationen dieser Fusionstypen Anwendung. Die Bezeichnung hierfür ist dann *hybride Fusion*.

Unterscheidung nach Fusionsebene

Der Begriff *Fusionsebene* nimmt eine weitere Klassifizierung der Sensordatenfusion vor. So unterscheidet man nach *Signalebene*, *Merkmalsebene* und *Entscheidungsebene*, in der englischsprachigen Literatur auch als *Pixel Level*, *Feature Level* und *Decision Level* bezeichnet [Kle99]. Gebräuchlich sind auch Bezeichnungen wie *Lower Level*, *Medium Level* und *Higher Level* [BI97].

Signalebene Auf *Signalebene* erfolgt die Verknüpfung minimal vorverarbeiteter Sensordaten oder Daten verschiedener Kanäle eines Sensors. Sie ist besonders für Sensoren geeignet, die das gleiche physikalische Phänomen in einem überlappenden Bereich messen.

Merkmalsebene Die Fusion auf *Merkmalsebene* mit dem Ziel der Vervollständigung der Umweltinformationen bzw. der Objektinformationen bedient sich bereits vorverarbeiteter Sensordaten. Basis der Verknüpfung bilden die extrahierten Merkmale verschiedener Sensoren, die das Fusionsystem zu einem neuen, größeren Merkmalsvektor kombiniert.

Entscheidungsebene Stärker vorverarbeitete Sensordaten dienen als Eingang für Fusionsmodule auf *Entscheidungsebene*. Auf dieser Ebene erfolgen letzte Verknüpfungen der Daten, um Entscheidungen bezüglich Objektidentität, Objektklasse oder ähnlichen Parametern als Ausgabe des Systems herbeizuführen.

Aufgrund der Nutzung stärker vorverarbeiteter Daten auf höheren Fusionsebenen und der damit verbundenen Einschränkungen durch Datenreduktion (z. B. durch Quantisierung, Reduktion von Dimensionen in Merkmalsvektoren) und Fehlern in vorgeschalteten Signalverarbeitungsstufen, bieten niedrige Fusionsebenen zumindest potentiell bessere Ergebnisse. Allerdings führen sie aufgrund der Datenmenge zu einem erhöhten Rechenaufwand oder die Fusion ist angesichts der Unterschiedlichkeit der Messdaten erst gar nicht möglich.


Unterscheidung nach Fusionsarchitektur

Eine weitere Form der Klassifikation stellt die Unterscheidung nach der Fusionsarchitektur dar. Bekannte, nach der Architektur unterschiedene Fusionsansätze sind *Sensor Level Fusion*, *Central Level Fusion* und *Hybrid Fusion*¹ [Kle99].


Sensor Level Fusion Bei der *Sensor Level Fusion* verarbeiten dem eigentlichen Fusionschritt vorgeschaltete Signalverarbeitungsstufen die Messdaten der Sensoren und leiten sie dann an das Fusionsmodul weiter (Abbildung 3.1). Die Schritte der Signalverarbeitung können im Bereich der Umgebungserfassungssysteme vor allem die Extraktion von Merkmalen, die

¹Hier besteht Verwechslungsgefahr mit dem Begriff *hybride Fusion*, der auf die Art der Fusion bzw. die Funktionalität bezogen ist!

Klassifikation, die Bestimmung bestimmter Objekteigenschaften, die Identifikation und auch das Tracking von Objekten umfassen. Die Signalverarbeitung ist hierbei optimal an den jeweiligen Sensor angepasst. Diese Architektur bietet sich vor allem bei der Fusion von Sensoren an, die unterschiedliche Phänomene messen. Die Menge der im Fusionsschritt zu verarbeitenden Daten ist in der Regel niedriger als bei Verwendung der Rohdaten der Sensoren.

Abbildung 3.1: Fusionsarchitektur *Sensor Level Fusion*

Central Level Fusion Im Unterschied zur *Sensor Level Fusion* dienen dem Fusionsmodul nur minimal vorverarbeitete Sensordaten als Eingangswerte. Die Vorverarbeitung beschränkt sich in der Regel auf einfache Filter und elementare Schätzverfahren (Abbildung 3.2). Weitergehende Signalverarbeitungsschritte erfolgen erst nach der Fusion der Sensordaten. Innerhalb dieser Fusionsarchitektur basiert der Großteil der Verarbeitungsschritte auf den Daten aller Sensoren. Dies bewirkt im Vergleich zur *Sensor Level Fusion* eine höhere Schätzgenauigkeit, vorausgesetzt, die verschiedenen Sensordaten entstammen nicht von voneinander unabhängigen Phänomenen. Die „zeitige“ Fusion der Daten bewirkt jedoch auch größere Komplexität und höhere Datenraten im Fusionsmodul. Die eigentliche Verknüpfung der Sensordaten kann aufgrund der Verschiedenartigkeit sehr schwierig oder gar unmöglich sein.

Abbildung 3.2: Fusionsarchitektur *Central Level Fusion*

Hybrid Fusion Auch innerhalb dieser Definition der Fusionsarchitekturen kommen in realen Umgebungen oft Ansätze zum Einsatz, die nicht isoliert einer dieser Gruppen zuzuordnen

sind. Bei der *Hybrid Fusion* sind sowohl Elemente der *Central Level Fusion* als auch Elemente der *Sensor Level Fusion* enthalten. So dienen dem (*Central Level*-)Fusionsmodul sowohl Rohdaten als auch Daten von Signalverarbeitungsmodulen, die parallel zum eigentlichen Fusionsprozess angeordnet sind, als Eingangswerte (Abbildung 3.3). Diese Fusionsarchitektur bietet die Vorteile von *Sensor Level Fusion* und *Central Level Fusion*, aber bedingt auch eine höhere Komplexität und größere Datenraten.




Abbildung 3.3: Fusionsarchitektur *Hybrid Level Fusion*

Weitere Einordnungsmöglichkeiten

Neben den oben genannten Kriterien existieren noch weitere Unterscheidungsmerkmale bzw. Einordnungsmöglichkeiten der Fusionsansätze; so zum Beispiel durch die Einführung des Begriffs Sensornetzwerke: *Sensornetzwerke* entstehen dann, wenn die einzelnen Sensoren als Knoten und die Fusion als Verbindung der Sensoren definiert werden. Dabei können sich in *dynamischen* Sensornetzwerken die Anzahl der Sensoren oder die Arten der Fusion ändern, während in *statischen* Sensornetzwerken diese Größen unverändert bleiben.

Weiterhin ist zu unterscheiden zwischen *homogenen* Anordnungen, bei denen Sensoren gleichen Typs Verwendung finden und *heterogenen* Anordnungen bei Verwendung von Sensoren unterschiedlichen Typs.

Eine weitere Möglichkeit der Sensordatenfusion sind *Algorithmenfusionen*, bei denen auf denselben Datensatz unterschiedliche Algorithmen zur Anwendung kommen und das Ergebnis die Fusion der Einzelresultate darstellt.

3.1.5 Werkzeuge zur Sensordatenfusion

Angesichts der sehr allgemein gehaltenen Definition des Begriffes *Sensordatenfusion* (siehe Abschnitt 3.1.1) existiert eine Vielzahl von Werkzeugen zur Verknüpfung von Daten aus verschiedenen Quellen. Einige der typischen Vertreter, die zum Teil auch für das beschriebene PreCrash-System zum Einsatz kommen, seien hier kurz genannt:

Logische Verknüpfungen Einige der einfachsten Verfahren zur Fusion von Sensordaten stellen *Logische Verknüpfungen* wie zum Beispiel UND-Verknüpfungen dar. Sie sind einfach zu realisieren und wenig rechenaufwendig.

Klassifikatoren Die Fusion mittels Klassifikator ermöglicht die Fusion von Daten unterschiedlicher Quellen durch die entsprechende Bildung eines Merkmalsvektors, in dem Anteile aller Sensoren enthalten sind. Derartige Fusionsansätze haben in der Regel *kooperativen* Charakter, da durch das Kombinieren der Daten in einem Merkmalsvektor und die anschließende Klassifikation erst die gewünschte Information verfügbar wird.

Stochastische Verfahren Die Verknüpfung von Daten mittels *stochastischer Verfahren* liefert Aussagen zu Wahrscheinlichkeiten von bestimmten Zuständen. Häufig ist diese Art der Fusion auf *Entscheidungsebene* anzutreffen. Ein bekanntes Beispiel für ein solches Verfahren ist die Verknüpfung mit Hilfe des *Satzes von Bayes* [BSMM97].

Fuzzy-Algorithmen Die Erweiterung der klassischen Mengenlehre und Logik in Form von *Fuzzy Logic* ermöglicht die Verknüpfung von „unscharfen“ Werten, die nicht eindeutig bestimmten Mengen zugeordnet sind. Ebenso wie die typischen stochastischen Verfahren findet diese Art der Datenfusion häufig auf *Entscheidungsebene* statt. Ausführliche Beschreibungen dieser Theorie sind beispielsweise in [ZY87] zu finden.

Kalman-Filter Die Verwendung eines *Kalman-Filters* dient in der Mehrzahl der Fälle *komplementären* oder *konkurrierenden* Fusionsansätzen. Das Filter verknüpft die Daten verschiedener Quellen und einer entsprechend eines Systemmodells ermittelten Prädiktion gewichtet zu einer Schätzung eines aktuellen Systemzustandes. In Abschnitt 4.3.2 findet sich eine detaillierte Beschreibung des Filters.

Grid of Evidence Ein Beispiel für ein Fusionsverfahren auf einer niedrigen Fusionsebene (*Sensor Level Fusion*) stellt das *Grid of Evidence* dar [ME85]. Die *kooperative* Verknüpfung von Sensordaten – zum Beispiel Abstandsmessungen – erhöht die Wahrscheinlichkeiten für die Existenz eines Objekts innerhalb der Zellen des Gitters und führt so zu einer Schätzung der Position des Objekts. Das Verfahren ist in Abschnitt 4.1.2 noch ausführlicher beschrieben.

Die aufgeführten Beispiele sind nur eine kleine Menge der Werkzeuge bzw. Algorithmen, die bei der Fusion von Daten zur Verfügung stehen.

3.2 Sensordatenfusion von Nahbereichsradaren und Laserscanner

3.2.1 Nutzen der Sensordatenfusion

Wie im Abschnitt 1.2 bereits beschrieben, stehen bei dem PreCrash-System neben guten Erkennungsleistungen vor allem ein zuverlässiger Betrieb auch unter schwierigen Umweltbedingungen im Vordergrund. Die Grundlage hierfür, eine möglichst vollständige, genaue, sichere

und widerspruchsfreie Beschreibung des Fahrzeugumfeldes, ist aufgrund der bei jedem Sensortyp vorhandenen Defizite bei bestimmten Bedingungen mit der Fusion mehrerer Sensoren potentiell besser realisierbar als bei der Verwendung eines Einzelsensorsystems. Bezogen auf das PreCrash-System, bestehend aus einem Laserscanner und zwei Nahbereichsradaren und in Anlehnung auf die in Abschnitt 3.1.2 aufgeführten Kriterien, stellen sich die erwarteten Vorteile bzw. der durch die Fusion erreichbare Gewinn, folgendermaßen dar:

Zuverlässigkeit Ein System, bestehend aus mehreren Sensoren, die gleiche oder ähnliche Messwerte liefern, ist zuverlässiger als ein Einzelsensorsystem², da Ausfälle einzelner Sensoren meist durch andere Sensoren ausgleichbar sind. So können im vorgestellten System die Radarsensoren Ausfälle des Laserscanners aufgrund der Ähnlichkeit der Messwerte zum Teil kompensieren und umgekehrt. Auch besteht bei der Verwendung mehrerer Sensoren die Möglichkeit, Ausfälle einzelner Sensoren (sicherer) zu detektieren, indem die Sensoren sich gegenseitig referenzieren.

Detektionswahrscheinlichkeit Der Einsatz mehrerer Sensorsysteme (auf unterschiedlicher physikalischer Basis) für eine Aufgabe schafft eine gewisse Redundanz, die die Detektionswahrscheinlichkeit erhöht. Es sind dabei mehrere Fälle zu unterscheiden:

Der erste Fall ist streng genommen ein Teil des Kriteriums *Zuverlässigkeit*. Das PreCrash-System muss auch unter schwierigen Umweltbedingungen arbeiten und alle Objekte im Sichtbereich der Sensoren detektieren. Ein typisches „Ausfallszenario“ ist in diesem System jedoch die Verschmutzung des Laserscanners, die zu einer eingeschränkten Detektionsleistung dieses Sensors führt. Aber auch problematische Wetterbedingungen wie Nebel, Schnee oder Regen können zur Störung des Laserscanners durch Absorption der Infrarotsignale führen. Die Nahbereichsradare sind von diesen Problemen weniger betroffen und können die Verschlechterung der Detektionsleistungen des Laserscanners zum Teil ausgleichen.

Der zweite Fall resultiert aus der Tatsache, dass praktisch jeder reale Sensor Schwierigkeiten bei der Detektion bestimmter Objekte oder Objektklassen hat. Die Verwendung von Sensoren, die auf unterschiedlicher physikalischer Basis (Wellenlänge) arbeiten, verbessert in diesen Fällen die Detektionsleistung des Gesamtsystems.

Detektionsprobleme, herrührend von Nickbewegungen des Fahrzeugs, bilden den dritten Fall. Hier verbessern die Nahbereichsradare aufgrund des größeren vertikalen Öffnungswinkels die Detektionsleistungen des PreCrash-Systems.

Genauigkeit Der Einsatz eines Laserscanners in dem PreCrash-System verbessert die Genauigkeit der Positionsbestimmung, da die Genauigkeit der Winkelangabe höher als die der Nahbereichsradare ist.

Sichtbereich Der Laserscanner erweitert den Sichtbereich des Gesamtsystems durch die Abdeckung eines größeren Entfernungsbereiches und Öffnungswinkels.

Mehrdeutigkeiten Wie bereits in Abschnitt 2.4 dargestellt, ist der Sichtbereich der Radare abhängig vom Rückstreuquerschnitt der Objekte. Das kann zur Detektion von Objekten

²Das gilt natürlich nur, wenn die Ausfallrate der Einzelsensorik mit der Ausfallrate der im Fusionssystem verwendeten Sensoren vergleichbar oder höher ist.

führen, die keine Ziele für ein PreCrash-System darstellen und damit unerwünschte Detektionen sind. Ein Beispiel für ein solches Objekt ist ein (großer) Gullydeckel. Die Verwendung von Radarsensoren allein könnte in bestimmten Situationen zu Falschauslösungen führen. Durch die Einbeziehung des Laserscanners ist die Erkennung solcher Situationen recht einfach möglich.

Zusätzliche Informationen Beide Sensoren liefern Aussagen bezüglich Abstand und Winkellage des Objekts. Der Laserscanner bietet darüber hinaus durch sein Messverfahren Informationen zur Kontur des Objekts.

Die verschiedenen Messverfahren (physikalische Basis) der Sensoren erweitern das Wissen über die beobachteten Objekte und damit den Merkmalsraum für eine eventuell geforderte Klassifikation.

Messraten Prinzipiell besteht die Möglichkeit, dass die Sensoren zu unterschiedlichen Zeitpunkten messen und somit die Messrate erhöhen. Von dieser Möglichkeit wird aber im beschriebenen PreCrash-System aufgrund einschränkender Randbedingungen des Messaufbaus kein Gebrauch gemacht.

Entsprechend der Forderungen nach einem zuverlässigen Betrieb und guten Erkennungsleistungen bietet die Kombination von Laserscanner und Nahbereichsradaren großes Potential (*konkurrierende und komplementäre Fusion*). Wie bei jeder Verwendung von Sensorik bzw. der Kombination unterschiedlicher Sensoren gibt es jedoch auch Nachteile, die zu berücksichtigen sind. Der folgende Abschnitt stellt die wichtigsten Nachteile vor.

3.2.2 Nachteile und Probleme der Fusion von Laserscanner und Radar

Die Nachteile der Fusion von Laserscanner und Radar sind in zwei Gruppen einzuteilen. Zum einen existieren die Nachteile der jeweiligen Sensoren, die den Wert des Sensortyps ganz allgemein für die Erfüllung der geforderten Aufgabe mindern. Zum anderen sind die Nachteile zu betrachten, die gerade aus der Kombination von Laserscanner und Nahbereichsradar entstehen.

Nachteile einzelner Sensoren

Nahbereichsradar Gegen den Einsatz des Nahbereichsradars sprechen Zulassungsprobleme, ungenaue Winkelangaben und die Tatsache, dass sich die Sensoren im Betrieb untereinander stören können.

Laserscanner Die Bauform heute verfügbarer Laserscanner lässt einen serienmäßigen Einbau dieses Sensors in ein Fahrzeug noch nicht zu. Auch sind Probleme wie die Verschmutzung der Optik noch nicht ausreichend gelöst. Ein weiterer Nachteil ist der geringe Sichtbereich in vertikaler Richtung.

Nachteile der Konstellation Laserscanner und Radar

Es ist anzuführen, dass beide Sensortypen sich nicht ideal im Sinne einer kooperativen Fusion ergänzen. Beide liefern hauptsächlich Informationen bezüglich Entfernung und ergänzen sich „nur“ durch Informationen bezüglich Relativgeschwindigkeit, genauerer Winkellage und unterschiedlich gewonnenen Rückstreuintensitäten. Dies stellt vor allem in Hinblick auf die (hier allerdings nicht benötigte) Klassifikation der Objekte keine optimale Lösung dar. Näher an einen kooperativen Ansatz käme ein Einsatz eines Kamerasystems als Ersatz für den Laserscanner. Hierbei ist der Bereich vor dem Fahrzeug, der abgedeckt wird, wesentlich größer als beim Laserscanner, der maximal 4 Ebenen erfasst. Es ist jedoch ein wesentlich höherer Aufwand bei der Signalverarbeitung zu erwarten, was sich im Preis des Gesamtsystems niederschlagen wird. Auch bestehen Probleme bezüglich Justierung und der Lichtempfindlichkeit (Abhängigkeit von Tageslicht bzw. Probleme bei wechselnden Lichtverhältnissen).

Ein weiteres Problem der Kombination von Laserscanner und Nahbereichsradaren ist ein Widerspruch zwischen zwei in Abschnitt 3.2.1 aufgeführten Punkten. Die Reduktion von Mehrdeutigkeiten bzw. unerwünschten Zielen durch den Laserscanner steht im Widerspruch zur Erhöhung der Zuverlässigkeit des Gesamtsystems durch die Radare. Das hat zur Folge, dass die Nahbereichsradare einen Komplettausfall des Laserscanners nicht kompensieren können. Da aber gerade die unterschiedliche physikalische Basis der verschiedenen Messverfahren und die Robustheit mindestens eines Sensorsystems gegenüber Umwelteinflüssen wichtig für den Aspekt der Zuverlässigkeit sind, ist hier keine Abhilfe in Form eines Ersatzes durch ein derzeit verfügbares Sensorsystem möglich.

3.2.3 Weitere Anwendungen

Die Kombination von Laserscanner und Nahbereichsradaren kommt natürlich noch für weitere Anwendungen in Frage, was die Forderung nach „Multifunktionalität“ (Abschnitt 1.4) erfüllt. Einige der möglichen Funktionalitäten sind im Folgenden aufgeführt und wichtige Kriterien kurz beschrieben:

- Collision Mitigation/Avoidance: Systeme, die in die Fahrdynamik eingreifen, um Unfallfolgen zu vermindern oder Unfälle ganz zu vermeiden, stellen eine Erweiterung eines PreCrash-Systems dar. Hier spielen neben der zuverlässigen Erkennung der Umwelt und der wirksamen Unterdrückung unerwünschter Ziele auch ein großer detektierbarer Entfernungsbereich eine wichtige Rolle.
- Stop & Go-Sensorik: Adaptive Tempomaten, die bis zum Stillstand des Fahrzeuges abbremsen und auch vom Stillstand aus beschleunigen, benötigen zuverlässige Informationen bezüglich der Fahrzeugumgebung. Das automatische Anfahren aus dem Stand heraus stellt insbesondere an den verfügbaren Sichtbereich der Sensoren hohe Anforderungen, um auch seitlich einlaufende Fußgänger erkennen zu können.
- Einparkhilfe: Probleme können auch hier schnell seitlich einlaufende Objekte darstellen. Zudem ist gerade hier die genaue Vermessung der Objekte (Kontur) von großer Bedeutung.

4 Einzelsignalverarbeitung der für die Fusion genutzten Sensortypen

Vorbereitend zur Fusion von Laserscanner und Radar wird in den nachfolgenden Abschnitten getrennt auf die Signalverarbeitung beider Sensortypen eingegangen. Wie im vorherigen Kapitel beschrieben und in Abbildung 1.4 dargestellt, sind, abhängig von der Ebene der Fusion, mehr oder weniger Schritte der Signalverarbeitung für einen einzelnen Sensor(-typ) notwendig, um eine für die eigentliche Funktion ausreichende Beschreibung des Fahrzeugumfeldes zu erhalten.

Die Fusion von Laserscanner und Nahbereichsradaren, die Inhalt des nächsten Kapitels ist, kann dabei auch als Erweiterung eines Einzelsensorsystems auf Basis eines Laserscanners durch einen weiteren Sensortyp – das Nahbereichsradar – verstanden werden. Abbildung 4.1 stellt die vereinfachte Struktur eines solchen Systems dar. Daher ist hier neben der vorberei-




Abbildung 4.1: Struktur des PreCrash-Systems

tenden Signalverarbeitung für die Nahbereichsradare die Einzelsensor-Signalverarbeitung bis hin zur Tracking-Stufe auf Basis der Daten des mehrlagigen Laserscanners zur Realisierung eines PreCrash-Systems beschrieben.

Für die Radarsensoren steht hier vor allem die homogene Fusion im Vordergrund. So kann es zum Beispiel sinnvoll sein, vor der Fusion der Radarsensoren mit dem Laserscanner beide Radarsensoren miteinander zu fusionieren. Die kooperative Fusion zweier Radarsensoren, die

nur Abstände, aber keine Winkel liefern, führt dann zu Aussagen bezüglich der Winkellage der Objekte im Sichtfeld beider Radare.

Ein wichtiger Teil des Gesamtsystems ist die Komponente zur Erkennung von Ausfällen einzelner Sensoren. Ein auf die Anwendung und Rahmenbedingungen angepasster Lösungsansatz ist ebenfalls in diesem Kapitel aufgeführt.

In den nachfolgenden Abschnitten wird von dem in Abschnitt 2.1 beschriebenen Systemaufbau ausgegangen.

Das verwendete Fahrzeugkoordinatensystem ist in Abbildung 4.2 dargestellt.

4.1 Signalverarbeitung für die Radarsensoren

Wie bereits in Abschnitt 2.2.3 beschrieben, liefern die Radarsensoren Aussagen zu Entfernung, Relativgeschwindigkeit, Amplitude und Lagewinkel des Ziels. Die Qualität der Winkelaussage vermindert sich jedoch bei den verwendeten Sensoren umso mehr, je weiter die Objekte seitlich liegen; das heißt, je größer der Winkel bezogen auf die x -Achse der Sensorik wird. Der Öffnungswinkel der Radarsensoren beträgt etwa 60° . Die Radare detektieren Objekte durchschnittlich bis maximal 30 m.

Im Rahmen der Arbeiten kamen auch Radare zum Einsatz, die keine Winkelangaben liefern. Speziell für diesen Typ, aber auch für die Verbesserung ungenauer Winkelangaben, beschreiben die Abschnitte 4.1.1, 4.1.2 und 4.1.3 mögliche Ansätze zur Vorverarbeitung der Daten dieser Sensoren. Voraussetzung für die Bestimmung des Winkels ist hierbei die geeignete Verknüpfung von Daten mehrerer Radarsensoren, die dasselbe Objekt detektieren. Die Sichtbereiche der Sensoren müssen sich dafür überlappen. Der Überlappungsbereich der Sensoren hängt bei Verwendung von Radarsensoren allerdings auch von dem Radarrückstreuquerschnitt¹ des Objekts ab.

Die erreichbare Güte der Positionsbestimmung bzw. Winkelschätzung hängt neben der Genauigkeit der Entfernungsmessungen vor allem von der Lage und der Form der Überlappungsbereiche ab. Als Ziel oder Optimierungskriterium für die Überlappungsbereiche gilt, dass im erforderlichen Sichtbereich des gesamten Sensorsystems möglichst viele, kleine, eindeutige und von möglichst vielen Sensoren beobachtete Bereiche entstehen. In [LSAD04] sind diese Kriterien und ein auf *Simulated Annealing* basierendes Optimierungsverfahren zur Lösung dieses Problems detaillierter beschrieben.

4.1.1 Fusion der Radare mittels Triangulation

Eine verbreitete Art der Fusion entfernungsmessender Sensoren zur Ermittlung der Winkellage eines Objektes in der horizontalen Ebene ist die Triangulation mit Hilfe des Bogenschnitts [BSMM97]. Voraussetzung dafür ist die Lage des Objektes innerhalb eines gemeinsamen Sichtbereiches von mindestens zwei Sensoren.

Die Grundidee der Ortsbestimmung mittels Bogenschnitt besteht in der Berechnung des Schnittpunktes N zweier Kreisbögen, deren Radien die von den Sensoren A und B gemessenen Entfernungswerte r_A und r_B mit den Kreismittelpunkten (x_A, y_A) und (x_B, y_B) – den Positionen der Sensoren im Fahrzeugkoordinatensystem – sind (Abbildung 4.2). Über den

¹Der Radarrückstreuquerschnitt σ_R (vgl. Abschnitt 2.2.2) wird oft auch als „radar cross section“ oder „RCS“ bezeichnet.




Abbildung 4.2: Positionsbestimmung mittels Triangulationsverfahren

Abstand s_{AB} zwischen den Sensoren A und B

$$s_{AB} = \sqrt{\Delta x_{AB}^2 + \Delta y_{AB}^2}, \quad (4.1)$$

den Winkel α zwischen s_{AB} und r_A

$$\cos \alpha = \frac{r_A^2 + s_{AB}^2 - r_B^2}{2r_A s_{AB}}, \quad (4.2)$$

den Winkel β zwischen s_{AB} und r_B

$$\cos \beta = \frac{r_B^2 + s_{AB}^2 - r_A^2}{2r_B s_{AB}}, \quad (4.3)$$

den Richtungswinkel t_{AN} zwischen der x -Achse und r_A

$$\tan t_{AB} = \frac{\Delta y_{AB}}{\Delta x_{AB}} \quad (4.4)$$

$$t_{AN} = t_{AB} - \alpha \quad (4.5)$$

4 Einzelsignalverarbeitung der für die Fusion genutzten Sensortypen

bzw. den Richtungswinkel² t_{BN} zwischen der x -Achse und r_B

$$t_{BA} = t_{AB} + 200gon \quad (4.6)$$

$$t_{BN} = t_{BA} - \beta \quad (4.7)$$

lassen sich die Koordinaten x_N und y_N des Punktes N mittels:

$$x_N = x_A + r_A \cos t_{AN} \quad (4.8)$$

$$y_N = y_A + r_A \sin t_{AN} \quad (4.9)$$

$$(4.10)$$

bzw.:

$$x_N = x_B + r_B \cos t_{BN} \quad (4.11)$$

$$y_N = y_B + r_B \sin t_{BN} \quad (4.12)$$

$$(4.13)$$

ermitteln.

Die Bestimmung des Lagewinkels mittels Triangulation ist sehr einfach und verhältnismäßig schnell, birgt jedoch einige Probleme:

Messgenauigkeit Aufgrund des geringen Abstandes zwischen den Radarsensoren im Verhältnis zu den detektierbaren Entfernungen bewirkt ein kleiner Fehler in den Entfernungsangaben r_1 oder r_2 einen großen Fehler bei der Bestimmung des Winkels θ . Der Fehler der Winkelbestimmung vergrößert sich noch mit steigenden Abständen r_1 und r_2 .

Eine Abhilfe in Form einer Vergrößerung des Abstandes zwischen den verschiedenen Sensoren ist durch die begrenzte Breite des Fahrzeugs als limitierender Faktor nicht möglich.

Modell Die Bestimmung der Lage des Objektes geht von punktförmigen Objekten aus. Detektieren die Sensoren unterschiedliche Bereiche des Objektes, verfälscht dies den Winkel θ (beispielhaft dargestellt für Winkelbestimmung an Fahrzeug in Abbildung 4.2). Das Einbringen eines Sensormodells in die Berechnung ist nicht möglich.

Mehrdeutigkeiten Abhängig von der Anordnung der Sensoren sind bestimmte Anordnungen ($r_1 = r_2$) für das System mehrdeutig. Ebenso entstehen bei Vorhandensein mehrerer Objekte im Erfassungsbereich Schnittpunkte, an denen sich keine Objekte befinden. Es kommt zu „Geisterobjekten“ (siehe Abbildung 4.2). Diese Geisterobjekte sind bei Vorhandensein einer Winkelangabe und in Abhängigkeit von der Genauigkeit dieser Winkelangabe bis zu einem gewissen Grade identifizierbar.

²Bei der hier verwendeten und aus der Geodäsie abgeleiteten *Neugradeinteilung* entsprechen 400 gon einem Vollwinkel von 360° . Die Messung des Winkels erfolgt im Uhrzeigersinn.

Objektabmessungen Generell ist die Bestimmung von Objektabmessungen bei Verwendung von Sensoren, die nur einzelne Punkte als Ziele liefern, schwierig. Das Triangulationsverfahren bietet auch keine Möglichkeit, Punktoobjekte von ausgedehnten Objekten zu unterscheiden. Das Problem ist in der Praxis jedoch nicht besonders schwerwiegend, da die Radare in der Regel immer die zu dem Sensor am nächsten liegenden Punkte bzw. Punkte aus den am nächsten zu den Radaren gelegenen Bereichen des Objektes detektieren.

4.1.2 Fusion der Radare mittels Grid of Evidence

Das Verfahren der Ortsbestimmung eines Ziels mittels *Grid of Evidence* (auch als *Occupancy Grid* bezeichnet) entstand 1983 im *Mobile Robot Laboratory* der *Carnegie Mellon University* [ME85]. Es diente dort der Transformation großwinkliger Abstandsmessungen von billigen, auf einem Roboter angebrachten SONAR-Sensoren in eine detaillierte räumliche Karte.




Abbildung 4.3: Positionsbestimmung mittels „Grid of Evidence“

Die Grundidee des Verfahrens, unter anderem beschrieben in [ME85], [Elf89] und [BFhS96], ist das Füllen der Zellen C des Gitters M mit Besetzungswahrscheinlichkeiten zwischen 0 und 1 unter Verwendung von Daten voneinander unabhängiger Sensoren und eine auf den Besetzungswahrscheinlichkeiten basierende Entscheidung, ob eine Zelle belegt ist oder nicht. Die Akkumulation der Wahrscheinlichkeiten (*diffuse evidence*) bei jeder Iteration lässt letztlich eine detaillierte und zuverlässige Karte der durch das zwei- oder dreidimensionale Grid repräsentierten Umgebung entstehen.

Für diesen Zweck ist jede Zelle mit einer Statusvariable $s(C)$ assoziiert, die als diskrete Zufallsvariable mit zwei Zuständen, *belegt* (O) oder *nicht belegt* (\bar{O}) definiert ist. Die Beschreibung des Status ist vollständig und die einzelnen Zustände schließen sich gegenseitig aus:

$$p(s(C) = O) + p(s(C) = \bar{O}) = 1. \quad (4.14)$$

Hierbei sind die Wahrscheinlichkeiten, dass eine Zelle an der Stelle x, y belegt ist, mit $p(O_{x,y})$ bzw. mit $p(\bar{O}_{x,y})$ für eine nicht belegte Zelle gegeben. Die Bestimmung dieser Besetzungswahrscheinlichkeit aus den zeitabhängigen Messungen r_1, \dots, r_T ist einer der wichtigsten Prozesse bei der Verwendung des Verfahrens. Die Ermittlung von $p(O_{x,y})$ und $p(\bar{O}_{x,y})$ geschieht in der Regel unter Verwendung eines stochastischen Sensormodells $p(O_{x,y}|r)$. Ein Beispiel für ein Modell eines idealen, eindimensional entfernungsmessenden Sensors ist in Abbildung 4.4 dargestellt. Im Falle der verwendeten Radarsensoren bestimmen vor allem der Sichtbereich der Sensoren (Öffnungswinkel) und die Genauigkeit der Entfernungsmessungen das Sensormodell.

Die Berechnung der Wahrscheinlichkeit für die Annahme, dass eine Zelle belegt ist, erfolgt




Abbildung 4.4: Eindimensionaler idealer Sensor

mit Hilfe des Bayes-Theorems:

$$p(O_{x,y}|r) = \frac{p(r|O_{x,y})p(O_{x,y})}{p(r|O_{x,y})p(O_{x,y}) + p(r|\bar{O}_{x,y})p(\bar{O}_{x,y})} \quad (4.15)$$

und unter Verwendung des Satzes der *vollständigen Wahrscheinlichkeit* [BSMM97]:

$$p(r) = p(r|O_{x,y})p(O_{x,y}) + p(r|\bar{O}_{x,y})p(\bar{O}_{x,y}). \quad (4.16)$$

Die einzelnen Zellen sind dabei als bedingt unabhängig angenommen, was die getrennte Aktualisierung der Wahrscheinlichkeitswerte ermöglicht und somit die Anwendung des Verfahrens wesentlich erleichtert. Vereinfachende Verfahren wie z. B. das *Histogram In-Motion Mapping* (HIMM) ersetzen die Verknüpfung mittels Bayes-Theorem durch einfache Additions- und Subtraktionsschritte [BI97].

Die Festlegung des Zustandes

$$s(C) = O \quad (4.17)$$

einer Zelle $m_{x,y}$ für einen bestimmten Zeitpunkt erfolgt in der Regel nach:

$$\{m_{x,y} \in M : p(O_{x,y}) \geq 0,5\}. \quad (4.18)$$

Davon abweichende Verfahren mit dynamisch wechselnden Schwellwerten sind ebenfalls denkbar.

Bei genügend langer Beobachtungszeit und ausreichender Information durch die Sensoren ist ein abschließendes Zusammenfassen der zusammengehörenden belegten Zellen zur Erfassung von Objektanmessungen oder -konturen möglich.

Einige Nachteile bei der Verwendung dieses Verfahrens für die Umfelderkennung im Automobilbereich sind im Folgenden genannt:

Statische Objekte Die Abbildung der Umgebung mit Hilfe eines Grid of Evidence setzt eine in Bezug auf das Grid statische Umgebung voraus bzw. funktioniert nur für statische Umgebungen korrekt. Im Automobilbereich beinhaltet die Umgebung eines Fahrzeugs jedoch in der Regel auch eine Vielzahl dynamischer Objekte, für die dann keine Ortsbestimmung mit dem Standardverfahren des Grid of Evidence möglich ist. Ein Ansatz zur Lösung dieses Problems besteht in der zusätzlichen Verschiebung der Wahrscheinlichkeitsgebiete entsprechend der Bewegung dynamischer Objekte unter Verwendung eines Tracking-Filters [Vog05].

Sichtbereich der Sensoren Die Sichtbereiche der Sensoren sind ein wichtiger Parameter bei der Erstellung eines Sensormodells. Bei der Verwendung von Radarsensoren hängt der Sichtbereich der Sensoren jedoch auch vom Rückstreuquerschnitt des Objekts ab. Dies führt zu Fehlern bei der Bestimmung der Belegungswahrscheinlichkeiten $p(O_{x,y})$ in Abhängigkeit von dem auf die Sensornormale bezogenen Winkel.

Rechenleistung Die bei der Anwendung des Verfahrens erforderliche Aktualisierung jeder Zelle in jedem Zeitschritt erzeugt einen, im Vergleich zu herkömmlichen Triangulationsverfahren, höheren Rechenaufwand und Speicherbedarf. Die Genauigkeit der Positionsbestimmung mittels Grid of Evidence steigt mit fallender Größe der einzelnen Zellen. Dies hat bei konstanter Größe des betrachteten Sichtbereiches eine steigende Anzahl von Zellen und damit weiter steigenden Rechenaufwand und Speicherbedarf zur Folge.

Mehrdeutigkeiten Durch symmetrische Anordnungen von Objekten hervorgerufene Mehrdeutigkeiten sind selbstverständlich auch durch diesen Algorithmus nicht auflösbar. Die Akkumulation bzw. die Reduktion von Wahrscheinlichkeiten löst solche Fälle jedoch automatisch nach einer gewissen Beobachtungszeit auf.

4.1.3 Fusion der Radare mittels Klassifikator

Eine weiteres, im Rahmen der Arbeiten entwickeltes Verfahren zur Bestimmung der Position statischer und dynamischer Objekte basiert auf einem Klassifikator, der eine Verbesserung der Genauigkeit der Winkelaussage der Radarsensorik oder auch die Erzeugung einer Winkelaussage, wenn die Sensorik keine liefern kann, bewirkt. Voraussetzung zur Anwendung dieses Algorithmus' sind mindestens zwei Sensoren, die in einem Überlappungsbereich Aussagen bezüglich der Abstände zu Objekten in diesem Bereich liefern können. Angaben bezüglich der Winkellage sind vorteilhaft.

Die Umsetzung mittels Klassifikation geschieht über die Einteilung des Bereiches vor den

4 Einzelsignalverarbeitung der für die Fusion genutzten Sensortypen

Sensoren in Unterbereiche in x -Richtung. Diese Unterteilungen ermöglichen die Bestimmung der Lage eines Objekts mit einer bestimmten Genauigkeit (Bild 4.5). Die Genauigkeit ist abhängig von der Breite der Unterbereiche.

Der Kern des Fusionsalgorithmus' besteht aus einem Klassifikator, der aus den Messwerten




Abbildung 4.5: Unterbereiche vor dem Fahrzeug

generierte Merkmalsvektoren mit Hilfe einer Datenbank klassifiziert.

Die Bildungsvorschrift für die Merkmalsvektoren in der Datenbank des Klassifikators lautet bei einem festgelegten Objektabstand in x -Richtung (z. B. $x_k = 5m$) folgendermaßen (siehe auch Bild 4.6):

$$r_i^2 = x_i^2 + b_i^2 \quad (4.19)$$

$$b_i^2 = r_i^2 - x_i^2. \quad (4.20)$$

Hierbei ist r_i der gemessene Abstand des Sensors i , x_i der Abstand vom Zielobjekt in x -Richtung (bei $x_i = x_k$) und b_i die y -Komponente oder seitliche Verschiebung des Ziels unter der Annahme, dass r_i , x_i und b_i ein rechtwinkliges Dreieck bilden. Die y -Komponenten b_i bzw. aus den b_i errechnete Werte der jeweiligen Sensoren bilden nun die Elemente des Merkmalsvektors, die Kombination dieser Werte ergibt ein Muster für eine bestimmte Objektposition. Weitere Elemente des Merkmalsvektors können die eventuell von den Radaren gelieferte Winkelinformationen α_i darstellen. Der nun von x_k unabhängige, resultierende Merkmalsvektor sieht damit für zwei Radare folgendermaßen aus:

$$m_k = \begin{pmatrix} w \cdot b_1 \\ w \cdot b_2 \\ (1 - w) \cdot \alpha_1 \\ (1 - w) \cdot \alpha_2 \end{pmatrix}. \quad (4.21)$$

Die Gewichtung der Merkmale b_i und α_i ist mittels Wichtungsfaktor w (mit $w \in \mathbb{R} : 0 \dots 1$) einstellbar. Die in der Datenbank des Klassifikators abgelegten Merkmalsvektoren stellen eine

Repräsentation des Sensormodells oder auch mehrerer Sensormodelle dar.

Die Vorgehensweise bei der Bildung der zu klassifizierenden Merkmalsvektoren aus den




Abbildung 4.6: Geometrische Basis

Messdaten ist im Folgenden beschrieben:

Um die Position eines Objektes innerhalb eines bestimmten Bereiches vor dem Fahrzeug bestimmen zu können, ist es notwendig, die Komponente x_i in jedem Klassifikationszyklus k ausgehend von einem oberen Schwellwert x_o stufenweise bis auf den unteren Schwellwert x_u herunterzusetzen, für jeden neuen Wert $x_{i,k}$ die $b_{i,k}$ zu errechnen und den so gebildeten Vektor zu klassifizieren (Abbildung 4.6). Der Wert $x_{i,k}$ entspricht damit einer Hypothese, dass sich das Objekt in der entsprechenden Entfernung befindet, zur der nun eine entsprechende y -Position bzw. das $b_{i,k}$ ermittelbar ist. Aus den Klassifikationsergebnissen ist das mit dem kleinsten Abstand zu einem Merkmalsvektor der Datenbank auszuwählen. Die dem entsprechenden Merkmalsvektor zugeordnete y -Position und das für die Erzeugung des Merkmalsvektors verwendete $x_{i,k}$ stellt dann die aus den Messwerten der Radare berechnete Schätzung der Position eines Objekts dar.

Die Schrittweite bei der Bestimmung der $x_{i,k}$ sollte unter Beachtung der benötigten Rechenzeit möglichst klein sein. Wichtig für die Eindeutigkeit der Ergebnisse ist die Wahl des Klassifikationsbereiches (Abbildung 4.7). Eine Möglichkeit der Einschränkung des Klassifikationsbereiches ist die Folgende: Die obere Schwelle s_o ist der kleinste Wert r_{min} (die kleinste gemessene Entfernung eines Sensors). Der Abstand eines Objekts in x -Richtung kann maximal r_{min} betragen. Dies ist genau dann der Fall, wenn sich das Objekt exakt vor dem Fahrzeug befindet ($b = 0$). Die untere Schwelle ergibt sich am untersten Schnittpunkt eines Kreises mit dem Radius r_i und dem Rand des untersuchten Gebiets.

Das Klassifikationsergebnis kann auch eine Zurückweisung der Klassifikation sein (Klasse NULL). Dies geschieht, wenn eine einstellbare Schwelle des Abstandes zum nächsten Merkmalsvektor der Datenbank überschritten wird (zu geringe Ähnlichkeit der Konstellation mit




Abbildung 4.7: Eindeutigkeitsbereich

den gegebenen Klassen).

Wie eingangs bereits angedeutet, bestehen prinzipiell mehrere Möglichkeiten der Nutzung dieses Fusionsansatzes. Zum einen kann das Ergebnis des Klassifikators direkt zur Bestimmung der Lage eines Objekts verwendet werden, falls die Sensorik keine Informationen bezüglich des Winkels liefert. Eine andere Anwendung ist die Verbesserung der Schätzung zur Lage eines Objekts; zum Beispiel bei unsicheren bzw. stark fehlerbehafteten Aussagen bezüglich des Winkels, aber gleichzeitig zuverlässigeren Entfernungsmessungen. Hierfür besteht die Möglichkeit der unterschiedlichen Gewichtung der Elemente des Merkmalsvektors. Im Gegensatz zu Triangulationsverfahren ist die Einbeziehung von Modellannahmen bei der Bestimmung der Objektposition möglich³.

Ein generelles Problem bei der Fusion mehrerer Radarsensoren ist die manchmal fehlerhafte Zuordnung von Messwerten verschiedener Sensoren zu einem (Schein-)objekt aufgrund einfacher Distanzkriterien. Gerade bei Verwendung weniger Sensoren, die pro Objekt nur sehr wenige Punkte oder nur einen Punkt detektieren, kommt es häufig zu solchen fehlerhaften Zuordnungen. Die auf einer Klassifikation basierende Algorithmik kann hier zum Teil Abhilfe schaffen, da nur bestimmte Kombinationen von Messwerten als gültig angesehen werden.

Die wichtigsten Nachteile des Verfahrens sind im Folgenden aufgeführt:

Rechenleistung In Abhängigkeit von der gewählten Auflösung, der Anzahl der Merkmalsvektoren in der Datenbank und der Art des benutzten Klassifikators können die Anforderungen an die Rechenleistung recht hoch sein.

³Ein typisches Beispiel für ein einfaches Modell ist, dass die Radarsensoren oft den am nächsten liegenden Punkt eines Objekts detektieren.

Mehrdeutigkeiten Durch die Anordnung der Radare und symmetrische Objektpositionen bedingte Mehrdeutigkeiten bei der Schätzung der Objektposition kann auch dieses Verfahren nicht auflösen.

Bei der Wahl eines zu großen Suchbereiches kann es ebenfalls zu Mehrdeutigkeiten kommen.

Objektabmessungen Im Gegensatz zu dem Verfahren Grid of Evidence bietet die Ortsbestimmung mit Hilfe eines Klassifikators keine Möglichkeit, Objektabmessungen zu bestimmen. Das Verfahren kann nur in einem begrenzten Rahmen Punktoobjekte von ausgedehnten Objekten unterscheiden. Aufgrund der Tatsache, dass die Radare fast immer Punkte aus den am nächsten zu den Radaren liegenden Bereichen des Objekts detektieren, bezieht sich die von dem beschriebenen Verfahren gelieferte Ortsangabe nahezu immer auf den zum eigenen Fahrzeug nächstliegenden Bereich des Objekts.

4.2 Signalverarbeitung für den Laserscanner

Die Signal(vor)verarbeitung für den Laserscanner spaltet sich in folgende Bereiche auf:

- Segmentierung und Filterung der Rohdaten
- Fusion der verschiedenen Scan-Ebenen
- Merkmalsextraktion

Die nachfolgenden Abschnitte gehen einzeln auf diese Punkte ein und beschreiben mögliche Ansätze mit ihren Vor- und Nachteilen.

4.2.1 Segmentierung, Filterung und Fusion der Rohdaten

Problemstellung

Der Begriff Segmentierung beinhaltet hier die Zusammenfassung mehrerer Messpunkte (Rohdaten) des Laserscanners anhand bestimmter Kriterien. Ziel der Segmentierung ist die Unterteilung der Rohdaten in Segmente, die realen Objekten im Sichtbereich des Sensors zugeordnet sind. Mögliche Fehler während der Segmentierung oder auch fehlerhafte Rohdaten können zu folgenden Problemen führen:

1. Ein Segment umfasst mehrere reale Objekte.
2. Ein Objekt wird in unterschiedliche Segmente unterteilt.
3. Einem realen Objekt ist kein Segment zugeordnet und damit ist das Objekt für nachfolgende Signalverarbeitungsstufen nicht mehr existent.
4. Es entsteht ein Segment, welches objektiv keinem realen Objekt zuzuordnen ist.

Während der erste Punkt zumeist Folgen für die Genauigkeit und den Aufwand des Tracking-Algorithmus hat, kann der zweite Punkt vor allem Schwierigkeiten bei der Klassifikation bzw. der Extraktion von Merkmalen der realen Objekte im Sichtbereich des Sensors verursachen. Die beiden letzten Punkte schlagen direkt auf die konkrete Anwendung, die letzte Stufe der

Signalverarbeitung, durch.

Bei der Segmentierung sind folgende Aspekte zu berücksichtigen, um eine möglichst effektive Signalverarbeitung in nachgeschalteten Stufen zu ermöglichen bzw. Vorbereitungen zu treffen, die Fehler und damit den Aufwand zur Behebung dieser in nachgeschalteten Signalverarbeitungsstufen zu minimieren:

Filterung Neben der eindeutigen Zuordnung von Rohdaten(-gruppen) zu realen Objekten ist die Verhinderung von Scheinsegmenten, die zu Scheinobjekten führen, sehr wichtig. Erreicht wird dies durch Ausfiltern von Messwerten, die durch Messfehler und nicht durch die korrekte Entfernungsbestimmung zwischen Sensor und Objekt zustande gekommen sind.

Prädiktion und Innovation Prädiktion und Innovation sind Teil des Trackings (siehe Abschnitt 4.3). Abhängig von Lage, Bewegungsrichtung, Abtastrate der Sensorik bzw. Taktrate des Tracking-Algorithmus und der Geschwindigkeit des Objekts zum Zeitpunkt $t - 1$ wird eine Voraussage über die Lage des Objekts zum Zeitpunkt t gemacht und mit der Messung zu diesem Zeitpunkt zu einer neuen Lage vereint. Die Lage ist hierbei jedoch auf einen Punkt bezogen. Die Bildung eines Bezugspunktes kann die Qualität der Lageschätzung beeinflussen. Aufgrund der Relativbewegung der Objekte ändert sich die Kontur dieser und beeinflusst die Bestimmung des Bezugspunktes. Dieser Einfluss ist zu minimieren, um keine Scheinbewegung der Objekte zu generieren.

Assoziation Die Assoziation als Teil des Trackings (genauer erläutert in Abschnitt 4.3) bestimmt die Zuordnung der Segmente zu bereits etablierten Objekten. Gerade bei hohen Geschwindigkeiten, geringen Abtastraten des Sensors und vielen Objekten ist die Zuordnung eines Segments zu einem Objekt erschwert. Insbesondere trifft das auf Objekte zu, für die aufgrund fehlender Historie noch keine verlässliche Prädiktionsaussage verfügbar ist. Einige aus den Segmenten extrahierte, möglichst aussagekräftige Merkmale können bei der Zuordnung von Segmenten zu bereits bestehenden Objekten helfen.

Klassifikation Im Falle einer nachgeschalteten Klassifikation sind neben der Betrachtung von Bewegungsabläufen der Objekte auch Form bzw. Kontur von großer Bedeutung für die Güte der Klassifikation. Hier sind ebenso wie bei der Assoziation einige aussagekräftige Merkmale der Segmente nützlich.

Segmentierung mittels einfachen Abstandskriteriums

Ein recht naheliegender und bekannter Ansatz zur Bildung von Segmenten besteht in der Suche nach zusammenhängenden Punkten anhand geometrischer Abstandskriterien. Hierbei erfolgt die Zusammenfassung der Entfernungsmessungen mit Hilfe von Suchbereichen, die schrittweise in φ -Richtung über die Messungen gelegt werden (Abbildung 4.8). Solange nachfolgende Messungen innerhalb des Suchbereiches liegen, sind sie dem aktuellen Segment zuzuordnen. Liegen nachfolgende Messungen außerhalb des Bereiches, beginnt ein neues Segment.

Mögliche und zum Teil vereinfachende Formen der Suchbereiche sind zum Beispiel:

- Rechteck




Abbildung 4.8: Elliptischer Suchbereich für die Segmentierung

- Kreis
- Ellipse

Ein Kriterium für die Qualität eines Suchbereiches ist die möglichst genaue Abbildung der geometrischen Eigenschaften des Messverfahrens und der physikalischen Eigenschaften des Sensors.

Im Falle des Laserscanners gilt für den Abstand d_{PQ} zwischen zwei benachbarten Messpunkten:

$$d_{PQ} = f(\gamma, r_P, r_Q). \quad (4.22)$$

Der Abstand der Messwerte in den Punkten P und Q hängt von der Winkelauflösung γ und den Abständen r_P und r_Q zwischen Sensor und den Punkten P bzw. Q ab und lässt sich am rechtwinkligen Fall zeigen:

$$r_P = \frac{y}{\sin \alpha_P} \quad (4.23)$$

$$r_Q = \frac{y}{\sin \alpha_Q} \quad (4.24)$$

$$x_P = \frac{y}{\tan \alpha_P} \quad (4.25)$$

$$x_Q = \frac{y}{\tan \alpha_Q} \quad (4.26)$$

$$d_{PQ} = x_Q - x_P \quad (4.27)$$

$$d_{PQ} = \frac{y}{\tan \alpha_Q} - \frac{y}{\tan \alpha_P} \quad (4.28)$$

$$d_{PQ} = \sqrt{r_Q^2 - y^2} - \sqrt{r_P^2 - y^2} \quad (4.29)$$

$$d_{PQ} = \sqrt{\left(\frac{y}{\sin \alpha_Q}\right)^2 - y^2} - \sqrt{\left(\frac{y}{\sin \alpha_P}\right)^2 - y^2}. \quad (4.30)$$

Gegeben sei nun ein minimaler Einstrahlwinkel α , ab dem die Totalreflexion der ausgesendeten Laserstrahlung an einem typischen Objekt erfolgt. Dieser Winkel bestimmt den maximalen Abstand d_{max} zweier benachbarter Messpunkte eines Objekts. Hierbei gilt die Annahme, dass beide Punkte auf einer Geraden liegen:

$$d_{max} = \lim_{r \rightarrow max, y \rightarrow min} \sqrt{r_Q^2 - y^2} - \sqrt{r_P^2 - y^2}. \quad (4.31)$$

Die Abmessungen des Suchbereiches im Falle eines Kreises ergeben sich mit den Skalierungsfaktoren S_K zu

$$r_K = S_K(r) \cdot d_{max} \quad (4.32)$$

$$= S_K(r) \cdot \left(\sqrt{r_{Q(max)}^2 - y_{min}^2} - \sqrt{r_{P(max)}^2 - y_{min}^2} \right), \quad (4.33)$$

wobei die Skalierungsfaktoren hier üblicherweise zur Parametrisierung der Toleranzschwelle für die Zuordnung von Punkten zu einem Segment zu verwenden sind.

Der Kreis als Suchbereich ist damit zwar dynamisch für steigende r anpassbar, eine nähere Adaption des Suchbereiches an die Abhängigkeit von α ist jedoch nicht gegeben. Die Suche, ausgehend von Punkt r_P , erfolgt in alle Richtungen mit demselben Abstandskriterium d_{max} . Die Verwendung eines rechteckigen oder elliptischen Suchbereiches ermöglicht die zusätzliche Einbeziehung der Abhängigkeit des Abstands d_{max} von α . Für die Ellipse gilt dann

$$r_E = \frac{\dot{x}^2}{a^2} + \frac{\dot{y}^2}{b^2} \quad (4.34)$$

mit der Winkelauflösung γ des Sensors und

$$a = r \sin \frac{\gamma}{2} \quad (4.35)$$

$$b = \left| \sqrt{r_{Q(max)}^2 - y_{min}^2} - \sqrt{r_{P(max)}^2 - y_{min}^2} \right|. \quad (4.36)$$

Die zusätzliche Abhängigkeit des Abstandes zweier Punkte vom Einstrahlwinkel α ist hiermit zwischen den Grenzfällen durch a für $r_P = r_Q$ und b für $\alpha \rightarrow \min$ in Form einer Ellipse gegeben:

$$d_{\max \dot{x}} = S_K(\dot{x}) \cdot a \quad (4.37)$$

$$d_{\max \dot{y}} = S_K(\dot{y}) \cdot b \quad (4.38)$$

$$r_E = \frac{\dot{x}^2}{(S_K(\dot{x}) \cdot a)^2} + \frac{\dot{y}^2}{(S_K(\dot{y}) \cdot b)^2}. \quad (4.39)$$

Zu beachten ist dabei noch, dass in der Regel für den minimal möglichen Einstrahlwinkel gilt:

$$\alpha_{\min} > 0^\circ. \quad (4.40)$$

Dies führt zu einem zusätzlichen Fehler bei der Bestimmung von b , da b in der Ellipse letztendlich in $\alpha = 0^\circ$ liegt. Dieser Fehler ist allerdings in der Regel für $S_k > 1$ und kleine α_{\min} vernachlässigbar.

Für die etwas vereinfachende Abbildung des Suchbereiches durch ein Rechteck gelten die Gleichungen 4.35 und 4.36 zur Berechnung der Abmessungen analog. Die Suchbereiche sind bei Verwendung von Ellipse oder Rechteck entsprechend des aktuellen Abtastwinkels zu drehen (Abbildung 4.8).

Die Adaption des Suchbereiches an verschiedene r entsprechend den Gleichungen 4.33, 4.39 und Abbildung 4.8 setzt jedoch die Wahl eines konstanten Wertes für y_{\min} voraus. Sinnvollerweise sollte $x_{\max} = r_{PQ, \max}$ der Abstand sein, ab dem an einem typischen Objekt (z. B. Fahrzeug), welches parallel zur y-Achse ausgerichtet ist, in der maximal detektierbaren oder benötigten Entfernung eine Totalreflexion der Laserstrahlung auftritt. Zudem ist die dynamische Adaption des Suchbereiches nur bis zu der Entfernung sinnvoll, in der die Aufweitung des Suchbereiches in Abhängigkeit der Winkelauflösung des Sensors gerade noch den Abmessungen eines zu detektierenden Objekts entspricht.

Diese Art der Zuordnung von verschiedenen Messpunkten zueinander ist allerdings nur innerhalb einer horizontalen Ebene des Laserscanners ohne weiteres nutzbar. Die Messwerte unterschiedlicher Ebenen können in Abhängigkeit vom vertikalen Öffnungswinkel und der Objektanmessungen für denselben Messwinkel durchaus verschiedene Ergebnisse liefern. Dies erschwert eine Zusammenfassung der verschiedenen Ebenen. Die mit dieser Methode unter anderem verwendbaren Möglichkeiten zur Zusammenfassung der verschiedenen Ebenen wären:

- **Getrennte Segmentierung und spätere Zuordnung der Segmente:** Die Zusammenfassung der Messwerte und Zuordnung dieser zu einem realen Objekt geschieht dabei für jede horizontale Ebene einzeln. Danach erfolgt die Zusammenfassung der Segmente der verschiedenen Ebenen zum Beispiel mit Hilfe eines geometrischen Abstandskriteriums per Mittelung. Der Aufwand für die Segmentierung vervielfacht sich jedoch mit der Anzahl der Ebenen. Zudem nutzt dieses Verfahren die Möglichkeiten zur Verbesserung der Detektionsleistungen des Sensors nur unzureichend aus. Ein Beispiel hierfür: Die gesamte Betrachtung aller Ebenen innerhalb eines Suchbereiches würde in einigen Fällen - im Gegensatz zur Betrachtung der einzelnen Ebenen (inklusive Vergleich mit deren Einzelschwellwerten S_1, S_2, S_3) - die Überschreitung eines Schwellwertes

S_G bedeuten, ab dem ein einfaches Rauschfilter eine Detektion als gesichert ansieht:

$$(A_1 < S_1) \quad (A_2 < S_2) \quad (A_3 < S_3) \quad (4.41)$$

$$(A_1 + A_2 + A_3) < S_G. \quad (4.42)$$

Abhilfe kann hier die (gewichtete) Filterung während der Zusammenfassung der Segmente schaffen, was aber den Aufwand weiter erhöht. Die getrennte Betrachtung der Ebenen kann aber im Zusammenhang mit dem oben geschilderten Problem auch zu zusätzlichen Unterteilungen in den verschiedenen Ebenen führen, wenn Messwerte fehlen, die in anderen Ebenen vorhanden sein können. All diese Probleme sind prinzipiell lösbar, führen jedoch zu hohem Aufwand (meist heuristisch) in der Signalverarbeitung.

- **Verknüpfung der Messwerte der verschiedenen Ebenen mittels Referenzebene:** Grundlage dieser Verknüpfungsvorschrift ist die Auswahl einer Referenzebene, von der ausgehend weitere Punkte in anderen Ebenen gesucht und miteinander verknüpft werden. Dabei ist ein (geometrisches) Distanzkriterium anzuwenden. Hier sind die Detektionsleistungen des Systems stark an eine Referenzebene geknüpft. Nicht vorhandene Daten in der Referenzebene oder zu große Abstände zwischen den Messwerten unterschiedlicher Ebenen können Objekte für das System unsichtbar machen.
- **Verknüpfung der Messwerte der verschiedenen Ebenen mittels (gewichteter) UND-(ODER-)Funktionen:** Die Messwerte der einzelnen Ebenen sind hier mittels (gewichteter) logischer Verknüpfungen miteinander zu verbinden und erst anschließend zu segmentieren. Das funktioniert jedoch nur unter der Annahme, dass dieselben Objekte in allen Ebenen detektiert werden. Dies ist in der Fahrzeugumgebung jedoch keine zulässige Annahme. Ein Beispiel hierfür ist das mögliche Detektieren der Fahrbahn in den unteren Ebenen durch die Nickbewegung des Fahrzeugs bei starkem Bremsen.
- **Durchlaufen aller Messpunkte und Zuordnung mittels Cluster-Verfahren:** Die Verknüpfung der Messpunkte aller Ebenen kann auch durch Cluster-Verfahren erfolgen. Derartige Verfahren sind allerdings unter Beachtung der geometrischen Eigenschaften des Messverfahrens sehr aufwendig und rechenzeitintensiv. Sie sind zudem oft rekursiv, was eine sichere Abschätzung der maximal benötigten Rechenzeit erschwert oder unmöglich macht.

Gitterbasierte Segmentierung

Die im vorherigen Abschnitt geschilderten Probleme, insbesondere bei der Verknüpfung der verschiedenen Ebenen und der damit verbundenen Schwierigkeiten, die möglichen Verbesserungen der Detektionsleistungen vollständig auszunutzen, führten während der Arbeiten zur Entwicklung eines gitterbasierten Segmentierungsverfahrens.

Die Abhängigkeiten der Suchbereichsgröße von der Entfernung r und dem Einstrahlwinkel α gelten natürlich analog 4.30, 4.35 und 4.36.

Die Grundidee der gitterbasierten Segmentierung ist sehr einfach: Die Suchbereiche zur Zuordnung von Messwerten zueinander stellen hier die Zellen eines Gitters (Grid) dar.

Die Messwerte aller Ebenen werden in dieses Gitter projiziert ①. Anhand eines einfachen Filterkriteriums (z. B. die Anzahl der Messpunkte pro Zelle) erfolgt eine Markierung der Zelle




Abbildung 4.9: Gitterbasierte Segmentierung

als belegt ②. Ein entsprechend der Anforderungen sehr einfacher Cluster-Algorithmus (zum Beispiel „Connected Component Labeling“) ordnet die jeweils zusammengehörenden Zellen zueinander ③. Diese Information, zurückprojiziert auf die Messwerte, stellt dann die Segmentierung und gleichzeitige Verknüpfung der verschiedenen Ebenen unter optimaler Ausnutzung der Detektivität der verschiedenen Ebenen dar ④. Die Suchbereiche, abgebildet durch die Zellen, sind nur einmal während des Starts zu berechnen (dynamische Anpassung für jeden Messzyklus ist allerdings auch möglich), was Rechenzeit spart.

Die Verwendung eines Gitters zur Segmentierung und ersten Filterung der Messwerte stellt einen sehr allgemeinen und anpassbaren Ansatz dar, der gerade die Kombination der einzelnen Messebenen sehr vereinfacht. Die Probleme, welche durch die Verwendung im vorherigen Abschnitt genannter Verknüpfungsalgorithmen vor allem in Hinsicht auf die Detektionsleistungen auftreten, sind hier eliminiert.

Die genaue Abbildung des Gitters ist entsprechend der Anforderungen frei definierbar. Zu beachten sind hier die Randbedingungen, welche zum Einen aus den geometrischen Eigenschaften des Messverfahrens und zum Anderen aus den Abmessungen der zu erwartenden Objekte resultieren. Auch bestimmen die Anforderungen der Anwendung den Aufbau des Gitters. Sinnvoll für die Verwendung des Ansatzes in der Fahrzeugumgebung ist eine feste Schrittweite in r -Richtung für besonders kleine r und für besonders große r aufgrund der Adaption an reale Objektgrößen. Im mittleren Teil sollte sich dann die Schrittweite zum Beispiel entsprechend Gleichung 4.30 zur Anpassung an die geometrischen Eigenschaften des Messverfahrens erhöhen. Die Winkelauflösung ist unter Beachtung der Winkelauflösung des Sensors entsprechend der zu erwartenden Objekte anzupassen (z. B. kleinere Auflösung im Randbereich aufgrund von instabilen Daten durch Bebauung und vor allem Bepflanzung). Abbildung 4.10 zeigt ein Beispiel eines solchen Gitters.




Abbildung 4.10: Beispiel für ein Segmentierungs-Gitter

Die Segmentierung lässt sich grundsätzlich auch für andere Sensortypen anwenden. Ein solches Beispiel stellt der in Kapitel 5.3.2 vorgestellte Fusionsansatz dar.

4.2.2 Merkmalsextraktion

Die Extraktion aller von den nachfolgenden Signalverarbeitungsschritten benötigten Daten bzw. Eigenschaften aus den zuvor zusammengefassten Messpunkten des Laserscanners findet in einer nachfolgenden Stufe statt. Sie reduziert gleichzeitig die Datenmenge beträchtlich. Die Leistung nachfolgender Signalverarbeitungsschritte hängt daher in einem großen Maße von der Qualität der hier extrahierten Daten ab.

Objektabmessungen und Orientierungswinkel

Der Laserscanner liefert aufgrund seiner hohen Winkelauflösung die Konturen detektierte Objekte. Diese Konturen bieten die Möglichkeit, Objekte unter Verwendung von dynamischen und geometrischen Modellen zu klassifizieren [CNR04, Lin03]. Ein Teilaspekt geometrischer Modelle ist dabei die Einteilung in geometrische Grundformen. Andere Aspekte geometrischer Modelle sind die Abmessungen und der Orientierungswinkel des detektierten Objekts. Auch das hier beschriebene PreCrash-System, bei dem die Einteilung in Objektklassen (Baum, Auto etc.) nicht notwendig ist, benötigt Informationen bezüglich der Abmessungen und des Orientierungswinkels des Objekts.

Die Bestimmung der Abmessungen und des Orientierungswinkels kann dabei durch den Einsatz unterschiedlicher Verfahren geschehen. Eine Variante, auf der *Radon-Transformation* basierend [ueb, PS02], zielt beispielsweise auf die Extraktion von Geraden mittels Durchführung der Transformation aus dem x, y -Raum (Ortsraum) in den (ρ, θ) -Raum ab. Eine Linie

ist neben der Form im Ortsraum

$$y = m \cdot x + k \quad (4.43)$$

auch durch deren Normale ρ und den Winkel θ zwischen Normale und Abszisse des Koordinatensystems beschreibbar. Transformiert in den (ρ, θ) -Raum ist die Gerade bzw. sind alle Punkte auf dieser Gerade durch einen Punkt $p(\rho, \theta)$ repräsentiert:

$$\begin{pmatrix} x \\ y \end{pmatrix} \cdot \begin{pmatrix} \cos \theta \\ \sin \theta \end{pmatrix} = \rho. \quad (4.44)$$

Die Aufgabe, aus mehreren Punkten p_i eine Gerade mit den gemeinsamen Parametern $p_G = (\rho_g, \theta_g)$ zu extrahieren, bedeutet hier die Suche nach den Parametern (ρ_i, θ_i) mit

$$\{\rho_i, \theta_i \in (\rho, \theta) : (\rho_i, \theta_i) = (\rho_g, \theta_g)\}. \quad (4.45)$$

Die Suche nach diesen Parametern findet durch Variation von ρ und θ für alle Punkte gemeinsam statt.

Ein ähnliches Verfahren zur Extraktion von Objekten, die sich wie zum Beispiel Geraden in geschlossener parametrisierbarer Form darstellen lassen, basiert auf der *Hough-Transformation* [Hou62, LB05]. Hier sind Geraden ähnlich wie bei der Radon-Transformation durch die Parameter ρ und θ repräsentiert. Mittels der Parametergleichung (*Hessesche Normalform*)

$$\rho_i = x \cdot \cos \theta + y \cdot \sin \theta \quad (4.46)$$

mit $\rho > 0$ und $0 \leq \theta < 2\pi$ lässt sich eine Kurve im (ρ, θ) -Raum aufzeichnen. Die Analyse des (ρ, θ) -Raumes besteht aus der Suche nach Häufungspunkten unter Betrachtung der Kurven aller Punkte.

Verfahren wie Radon- und Hough-Transformation sind sehr rechenaufwendig [NMTS05]. Zudem liefern sie nicht, wie bei der Anwendung benötigt, die Anfangs- und Endpunkte der Geraden. Auch die Bildung einer Segmentbox aus den extrahierten, zusammengehörenden Geraden bleibt Aufgabe nachfolgender Verarbeitungsschritte. Ebenso kann die Verwendung dieser Verfahren in Abhängigkeit von Auflösung zur Erkennung mehrerer Geraden (mehrere Häufungen im (ρ, θ) -Raum) statt einer gemeinsamen Geraden führen.

Eine vereinfachte Möglichkeit, die Abmessungen und den Orientierungswinkel des Segments ohne die Extraktion von Geraden zu bestimmen, besteht in der Verwendung der „Dreipunkte-Methode“ (Abbildung 4.11). Die drei Punkte sind [Mö4]:

- **Punkt mit kleinstem Abtastwinkel** p_1 Bei dem sich im Uhrzeigersinn drehenden Spiegel des Laserscanners ist dies der erste detektierte Messpunkt eines Segments.
- **Punkt mit geringstem Abstand zum Ursprung** p_2 Dieser Punkt hat den geringsten Abstand zum Ursprung des Sensorkoordinatensystems.
- **Punkt mit größtem Abtastwinkel** p_3 Bei dem sich in Uhrzeigersinn drehenden Spiegel des Laserscanners ist dies der letzte detektierte Messpunkt eines Segments.




Abbildung 4.11: Bestimmung des Orientierungswinkels mittels Dreipunkte-Methode

Nach Berechnung der Abstände zwischen diesen genannten Punkten

$$d_{P_i, P_j} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (4.47)$$

ist für die Bestimmung des Lagewinkels der Segmentbox die Seite mit dem größten d_{P_i, P_j} zu wählen, um den Fehler bei der Winkelbestimmung zu minimieren. Der aus den ausgewählten Punkten berechnete Orientierungswinkel

$$\beta = \arctan \frac{|y_i - y_j|}{|x_i - x_j|} \quad (4.48)$$

ist aufgrund der Betragsbildung ohne Vorzeichen. Die notwendige Vorzeichenkorrektur erfolgt durch die Bestimmung des Anstiegs der Geraden.

Die aus allen Koordinaten ermittelten Maxima und Minima legen nun die Abmessungen der Segmentbox fest.

Bei Verwendung dieses Verfahrens entsteht durch die vereinfachende Modellannahme rechteckiger Segmente ein Fehler bei der Berechnung von Orientierungswinkel und Abmessung unregelmäßiger bzw. stark von dieser Modellannahme abweichender Objekte. Aufgrund verhältnismäßig kompakter Abmessungen typischer Objekte im Fahrzeugumfeld (Fahrzeuge, Fußgänger, Bäume etc.) wirkt sich dieser Fehler in der Regel nicht negativ auf die Eigenschaften eines PreCrash-Systems aus.

Referenzpunkt

Ein wichtiger, der Segmentierung nachfolgender Schritt ist das Tracking. Das Tracking-Filter benötigt einen Bezugs- bzw. Referenzpunkt des Segments. Alle weiteren Verarbeitungsschritte

innerhalb der Tracking-Stufe sind in erster Linie auf diesen Punkt bezogen. Um eine hinreichend exakte Schätzung des Tracking-Filters zu ermöglichen, muss dieser Referenzpunkt frei von Einflüssen sein, die nicht aus der Relativbewegung des Objekts herrühren. Prinzipiell




Abbildung 4.12: Bewegung des Referenzpunktes bei schwankender Anzahl von Messwerten

stehen mehrere Varianten für die Extraktion eines Referenzpunktes zur Auswahl:

- **Mittel- oder Endpunkte der Seiten** Diese Referenzpunkte bestehen aus den Mittel- oder Endpunkten bestimmter Seiten eines Segments. Sie unterliegen jedoch starken Einflüssen durch eine schwankende Anzahl der dem Segment zugeordneter Messpunkte. Das Verlassen des Sichtbereiches oder die Veränderung der Beobachtungsperspektive des Sensors bedingen solche Schwankungen und führen mit ihrem Einfluss auf die relative Lage des Bezugspunktes zum realen Objekt zu Scheinbewegungen. Derartige Scheinbewegungen können gerade beim Verlassen des Sichtbereiches durch das Objekt zu Fehlauflösungen führen, da sie eine scheinbare Richtungsänderung in die Richtung des eigenen Fahrzeuges hervorrufen (Abbildung 4.12).
- **Mittelpunkt der Segmentbox** Der Mittelpunkt der Segmentbox unterscheidet sich in seinen Eigenschaften kaum von den Mittel- oder Endpunkten der Seiten. Er unterliegt denselben Einflüssen durch Schwankungen in der Anzahl der Messpunkte.
- **Schwerpunkt der Messwerte** Bei der Bestimmung des Schwerpunktes p_s fließen alle N Abstands- und Winkelmessungen bzw. die daraus ermittelten Punkte $p_i(x, y)$ eines

Segments ein:

$$p_s = \frac{1}{N} \cdot \sum_{i=1}^N p_i(x, y). \quad (4.49)$$

Aufgrund der geometrischen Eigenschaften des Messverfahrens liegt der Großteil der Messpunkte in dem dem Sensor zugewandten Bereich des Objekts, was sich auch auf die Lage des Schwerpunktes der Messwerte auswirkt. Verlassen Objekte den Sichtbereich des Sensors, ist hier die Bewegung des Referenzpunktes relativ zum Objekt geringer als bei den Mittelpunkten der Segmentbox bzw. der Seiten (Abbildung 4.12).

- **Verwendung mehrerer Tracking-Filter** Dieses in [Lin03] beschriebene Verfahren kann für Objekte zur Anwendung kommen, bei denen sich die Kontur des Objekts durch zwei Geraden abbilden lässt. In diesem Fall basiert das Tracking auf zwei Referenzpunkten, welche auf den Mittelpunkten der beiden Geraden liegen. Zwei Tracking-Filter übernehmen getrennt für jeweils einen Referenzpunkt die Schätzung des Zustandsvektors. Die Auswahl der Schätzung im jeweiligen Zyklus erfolgt dann entsprechend der „Stabilität“ der beiden Referenzpunkte; das heißt, dass die für das Objekt benutzte Schätzung auf der Schätzung des Referenzpunktes beruht, dessen Segmentabschnitt innerhalb der letzten Zyklen keine oder die wenigsten Schwankungen in der Anzahl der Messpunkte aufweist. In vielen Fällen ist nur eine Seite eines Segments von derartigen Schwankungen betroffen (zwei Beispiele in Abbildung 4.12). In solchen Fällen hilft dieses Verfahren, Bewegungen des Referenzpunktes relativ zum Objekt zu vermindern oder ganz zu verhindern. Der durch den Einsatz zweier Tracking-Filter stark erhöhte Rechenaufwand ist jedoch ein Nachteil dieses Lösungsansatzes.

Ein für die Anwendung praktikabler Ansatz ist die Verwendung des Schwerpunktes der Messwerte. Hier sind die Anforderungen an die Rechenleistung vergleichbar mit denen des auf dem Mittelpunkt der Segmentbox oder der Seiten des Segments basierenden Referenzpunktes und niedriger als bei Verwendung zweier Tracking-Filter. Er ist aber gerade in dem für eine PreCrash-Anwendung wichtigen Fall einer engen Vorbeifahrt und dem damit verbundenen Verlassen des Sichtfeldes noch ausreichend stabil gegenüber einer Verringerung der Anzahl von Messpunkten.

Weitere Merkmale

Ein weiteres, aus den Rohdaten des Laserscanners extrahierbares Merkmal ist die Kontur eines Objektes bzw. typische Eigenschaften der Kontur von Objekten. Neben der Einteilung in Objektklassen können diese Merkmale auch der sichereren Zuordnung im Assoziationsschritt des Tracking-Filters dienen. Die Abmessungen der Segmentboxen sind ebenfalls einfache Anhaltspunkte zur Unterstützung des Assoziationsschrittes.

Ein weiteres, über mehrere Objektzyklen extrahiertes Kennzeichen kann die Anzahl der Messpunkte eines Segments sein. Eine stark fallende Anzahl von Messpunkten bedeutet eine ungenauere bzw. unvollständige Messung. Das Tracking-Filter kann diese Information bei der Gewichtung der Messungen berücksichtigen.

4.3 Tracking

Der Begriff Tracking umfasst im Zusammenhang mit einem Umfelderkennungssystem alle Verarbeitungsschritte, die der Verfolgung von (bewegten) Objekten dienen. Ziel dieser Verfolgung ist zum einen die Extraktion von Informationen über den Verlauf der Bewegung und die Lage eines Objektes und zum anderen die Verminderung von negativen Einflüssen, herrührend von meist zufälligen Messfehlern (oft *normalverteiltes* Rauschen). Die extrahierten Informationen können die Geschwindigkeit der Bewegung, die Beschleunigung sowie Informationen bezüglich der Lage zu einem bestimmten Zeitpunkt sein. Die extrahierten Informationen bilden damit den geschätzten Zustand eines Objekts.

Die Genauigkeit der ermittelten Lage- und Bewegungsinformation hängt neben dem verwendeten Tracking-Algorithmus auch von der Genauigkeit der Messungen bzw. dem Messfehler und der Abtastrate der zyklischen Messungen ab.

Das Tracking lässt sich in folgende drei Verarbeitungsschritte unterteilen:

Prädiktion In diesem Verarbeitungsschritt erfolgt die rechnerische Bestimmung der Lage- und Bewegungsinformationen für einen, oft in der Zukunft liegenden Zeitpunkt anhand bekannter Geschichte und physikalischer Gesetzmäßigkeiten. Die mathematische Abbildung physikalischer Gesetzmäßigkeiten geschieht unter der Verwendung oft stark vereinfachter Modelle. Die Qualität solcher Modelle entscheidet unter anderem über die Qualität der Zustandsschätzung. Die Wahl komplexerer, besser an die physikalischen Eigenschaften realer Objekte angepasster Modelle führt aber meist zu erhöhtem Rechen- und Implementationsaufwand.

Assoziation Insbesondere in Beobachtungsräumen, in denen sich in der Regel mehrere Objekte (Multi-Target-Tracking) befinden und diese nicht durch zusätzliche Merkmale eindeutig über verschiedene Messzyklen identifizierbar sind, übernimmt diese Komponente die Zuordnung eines in früheren Messzyklen beobachteten Objekts zu einer Messung eines oder mehrerer Sensoren im aktuellen Messzyklus. Fehler in diesem Bearbeitungsschritt wirken sich besonders negativ auf die Ergebnisse des Tracking aus. Sie führen vor allem während der Zeitpunkte der falschen Zuordnung zu komplett falschen Zustandsschätzungen.

Innovation Die Bestimmung der aktuellen Lage und anderer bewegungsrelevanter Informationen erfolgt einerseits durch die Prädiktion und andererseits durch den Einbezug aktueller Messungen bzw. extrahierter Merkmale aus aktuellen Messungen. Der Innovationsschritt führt beide Informationen gewichtet zu einer Schätzung des aktuellen Zustands zusammen. Die Gewichtung kann sowohl dynamisch als auch statisch erfolgen. Eine Verschiebung der Anteile hin zur Prädiktion glättet die Ergebnisse stärker, eine größere Gewichtung der Messung führt zu Ergebnissen, die sich schneller auf Veränderungen der Messwerte einstellen.

Tracking-Verfahren lassen sich anhand verschiedener Parameter unterscheiden. Ein naheliegendes Unterscheidungskriterium ist der verwendete Algorithmus. Weitere Kriterien sind oft auf die Art und die Anzahl der verwendeten Modelle bezogen. Die Modelle werden so zum Beispiel in lineare und nichtlineare Modelle unterschieden oder Tracking-Filter mit nur

einem verwendeten Modell von Filtern, die unterschiedliche Modelle nutzen, abgegrenzt. Eine weitere Möglichkeit der Differenzierung ist die Unterscheidung in *Single-Target-Tracker* und *Multi-Target-Tracker*.

4.3.1 Alpha-Beta-Tracker

Eines der einfachsten Verfahren zum Verfolgen von Objekten ist der α - β -Tracking-Algorithmus. Das Filter schätzt den Zustand mit Hilfe statischer Gewichtungsfaktoren α und β . Damit ergibt sich beispielsweise eine neue Positionsschätzung x_k und eine neue Geschwindigkeitsschätzung v_{x_k} aus den vorhergehenden Schätzungen x_{k-1} , $v_{x_{k-1}}$ und der Zykluszeit T

$$x_k = x_{k-1} + T v_{x_{k-1}} + \alpha r_k \quad (4.50)$$

$$v_{x_k} = v_{x_{k-1}} + \frac{\beta}{T} r_k \quad (4.51)$$

mit dem Residuum r_k , welches die Differenz zwischen gemessener Position z_k und prädizierter Position enthält [BS89]:

$$r_k = z_k - (x_{k-1} + T v_{x_{k-1}}). \quad (4.52)$$

Die Wahl der Gewichtungsfaktoren geschieht unter Verwendung von Vorwissen bezüglich der Varianzwerte der Prädiktion (σ_P^2) und der Messung (σ_z^2), beispielsweise mit:

$$\alpha = \frac{\sigma_P^2}{\sigma_P^2 + \sigma_z^2}. \quad (4.53)$$

Der α - β -Tracking-Algorithmus zeichnet sich durch geringe Anforderungen an die benötigte Rechenleistung und die einfache Implementierung aus, erreicht aber durch die statische Gewichtung von Messung und Prädiktion nicht die Leistung eines Filters, das diese Faktoren adaptiv einstellt. Der nachfolgende Abschnitt stellt ein solches, für ein Umfelderkennungssystem besser geeignetes Verfahren vor.

4.3.2 Kalman-Filter

Ein für das Tracking von Objekten bekannter und weit verbreiteter Ansatz ist das Kalman-Filter. Das Kalman-Filter, 1960 von Rudolf Kalman für lineare, zeitdiskrete Systeme entwickelt [Kal60], ist ein stochastischer Zustandsschätzer. Es schätzt den Zustand eines Systems anhand teilweise redundanter Messungen, die von Rauschen überlagert sind. Das Filter minimiert dabei die Summe der Fehlerquadrate [Kal60, May79, WB01] und integriert alle vorhandenen Informationen wie zum Beispiel Messwerte und Vorwissen über das System oder die Parameter der Messfehler rekursiv in den Schätzwert. Dabei berücksichtigt es die Messwerte und die mittels Systemmodell gewonnene Prädiktion variabel gewichtet.

Das Grundprinzip des Kalman-Filters beruht auf der Kombination von normalverteilten, bedingten Wahrscheinlichkeiten $P(s_j|z_i)$ [May79, Dol05]. Dabei ist $P(s_j|z_i)$ die Wahrscheinlichkeit, dass sich das System bei einer gegebenen Messung z_i im Zustand s_j befindet (Abbildung 4.13). Mess- oder Zustandswerte bilden damit eine bedingte Wahrscheinlichkeit, mit




Abbildung 4.13: Gewichtete Kombination unsicherer Messwerte

einer Gauß-Glockenkurve und dem Maximum an der Stelle des Messwertes, wenn die Messfehler normalverteilt sind. Ein wichtiger Parameter dieses Kurvenverlaufs ist die Varianz σ^2 , die die Sicherheit bzw. Genauigkeit des Messwertes oder der Schätzung angibt. Große σ^2 bezeichnen ungenaue Messungen oder Schätzungen.

Für die Kombination von zwei Messwerten (wobei im Falle eines Tracking-Filters anstelle des zweiten Messwertes auch eine Prädiktion stehen kann) z_1 und z_2 zum Zeitpunkt k mit den Varianzen $\sigma_{z_1}^2$ und $\sigma_{z_2}^2$ bietet sich eine gewichtete Linearkombination an:

$$\hat{s}_k = w_1 z_1 + w_2 z_2 \quad (4.54)$$

mit

$$w_1 + w_2 = 1. \quad (4.55)$$

Der bei der Schätzung zu minimierende Fehler zum Zeitpunkt k

$$\epsilon_{s_k} = s_k - \hat{s}_k \quad (4.56)$$

ergibt sich aus der Differenz zwischen wahrem Wert s_k und der Schätzung \hat{s}_k und lässt sich für folgende w_1 und w_2 minimieren:

$$w_1 = \frac{\sigma_{z_2}^2}{\sigma_{z_1}^2 + \sigma_{z_2}^2} \quad (4.57)$$

$$w_2 = \frac{\sigma_{z_1}^2}{\sigma_{z_1}^2 + \sigma_{z_2}^2}. \quad (4.58)$$

Die Schätzung \hat{s}_k ergibt sich damit zu

$$\hat{s}_k = \frac{\sigma_{z_2}^2}{\sigma_{z_1}^2 + \sigma_{z_2}^2} \cdot z_1 + \frac{\sigma_{z_1}^2}{\sigma_{z_1}^2 + \sigma_{z_2}^2} \cdot z_2. \quad (4.59)$$

Die resultierende, der Schätzung \hat{s}_k zugeordnete Varianz

$$\sigma_{\hat{s}_k}^2 = \left(\frac{1}{\sigma_{z_1}^2} + \frac{1}{\sigma_{z_2}^2} \right)^{-1} \quad (4.60)$$

4 Einzelsignalverarbeitung der für die Fusion genutzten Sensortypen

ist für Varianzen $\sigma_{z_1}^2 > 0$ und $\sigma_{z_2}^2 > 0$ immer kleiner als die kleinste Varianz der kombinierten Messwerte. Die Wahrscheinlichkeitsdichtefunktion $P(s_k|z_1, z_2)$ verläuft nun enger um den Schätzwert \hat{s}_k , was einen Zugewinn an Informationen über den wahren Wert s_k bedeutet. Neben der Kombination von zwei Messungen spielt vor allem beim Tracking die Kombination mit einer Prädiktion \hat{s}_k^- eine große Rolle. Die Prädiktion resultiert aus der Schätzung \hat{s}_{k-1} des vorhergehenden Zeitschrittes $k-1$ und der Berücksichtigung der Veränderung $s_M[t_k - t_{k-1}]$ des Zustandes zwischen zwei Zeitschritten:

$$\hat{s}_k^- = \hat{s}_{k-1} + s_M[t_k - t_{k-1}]. \quad (4.61)$$

Die Zustandsänderung $s_M[t_k - t_{k-1}]$ ist durch ein geeignetes Modell beschrieben. Dieses Modell ist nur eine vereinfachte Abbildung der Wirklichkeit, was die Unsicherheit der Prädiktion im Vergleich zur vorherigen Schätzung \hat{s}_{k-1} wieder um $\sigma_M[t_k - t_{k-1}]$ vergrößert:

$$\sigma_{\hat{s}_k^-}^2 = \sigma_{\hat{s}_{k-1}}^2 + \sigma_M[t_k - t_{k-1}]. \quad (4.62)$$

Die Gleichung 4.59 nun mit der Messung z_k und der Prädiktion \hat{s}_k^- anstelle der Messungen z_1 und z_2 lässt sich gleichzeitig umformen zu

$$\hat{s}_k = \hat{s}_k^- + \frac{\sigma_{\hat{s}_k^-}^2}{\sigma_{\hat{s}_k^-}^2 + \sigma_{z_k}^2} \cdot (z_k - \hat{s}_k^-), \quad (4.63)$$

mit dem Gewichtungsfaktor K (auch als *Kalman-Gain* bezeichnet)

$$K = \frac{\sigma_{\hat{s}_k^-}^2}{\sigma_{\hat{s}_k^-}^2 + \sigma_{z_k}^2}. \quad (4.64)$$

Die der Schätzung \hat{s}_k zugeordnete Varianz $\sigma_{\hat{s}_k}^2$ kann nun mit

$$\sigma_{\hat{s}_k}^2 = \sigma_{\hat{s}_k^-}^2 + K \cdot \sigma_{z_k}^2 \quad (4.65)$$

ermittelt werden und ist das Äquivalent zu der in Gleichung 4.60 berechneten Varianz.

Der Filter-Algorithmus bzw. die Prädiktor-Korrektor-Struktur des Kalman-Filters lässt sich nun folgendermaßen für den allgemeinen, meist mehrdimensionalen Fall beschreiben: Ein Zustand $\hat{\mathbf{s}}_k^-$ (entspricht \hat{s}_k aus dem vorherigen Abschnitt im eindimensionalen Fall) wird mit Hilfe des geschätzten Zustandes $\hat{\mathbf{s}}_{k-1}$ aus dem vorherigen Zyklus $k-1$, der Zustandsübergangsmatrix \mathbf{A} und eines Regeleingriffes $\mathbf{B}\mathbf{u}_k$ (oft nicht vorhanden) prädiziert („a priori-Schätzung“):

$$\hat{\mathbf{s}}_k^- = \mathbf{A}\hat{\mathbf{s}}_{k-1} + \mathbf{B}\mathbf{u}_k. \quad (4.66)$$

Die Zustandsübergangsmatrix \mathbf{A} beschreibt dabei das Modell für die Veränderung des Zustandes zwischen zwei Zeitschritten. Der für diese Prädiktion erwartete Fehler errechnet sich aus:

$$\mathbf{P}_k^- = \mathbf{A}\mathbf{P}_{k-1}\mathbf{A}^T + \mathbf{Q}. \quad (4.67)$$

Hier fließt neben der Zustandsübergangsmatrix \mathbf{A} auch der Modellfehler \mathbf{Q} ein, der die Abweichung des Modellverhaltens von der Realität beschreibt (vgl. Gleichung 4.62). Für den Innovationsschritt wird eine in jedem Zyklus durchgeführte Messung \mathbf{z}_k benötigt, die mit dem echten Zustand \mathbf{s}_k des Systems folgendermaßen zusammenhängt:

$$\hat{\mathbf{z}}_k = \mathbf{C}\hat{\mathbf{s}}_k + \mathbf{v}_k. \quad (4.68)$$

Hierbei erfasst \mathbf{C} die Abhängigkeit zwischen \mathbf{s}_k und \mathbf{z}_k bei einer „fehlerfreien“ Messung. Messfehler sind durch \mathbf{v}_k beschrieben und typischerweise mit der sogenannten Messfehlerkovarianzmatrix \mathbf{R} spezifiziert. Die Zuordnung der Messwerte zu den prädizierten Werten geschieht innerhalb des Assoziationsschrittes, oft unter Verwendung eines Suchbereiches, welcher sich von dem erwarteten Prädiktionsfehler \mathbf{P}_k^- und der Messungenauigkeit, die in \mathbf{R} abgelegt ist, ableitet. Die Gewichtung der Messung gegenüber der Prädiktion bestimmt der sogenannte Kalman-Gain entsprechend der Prädiktionsfehlerkovarianzmatrix \mathbf{P}_k^- und der Messfehlerkovarianzmatrix \mathbf{R} :

$$\mathbf{K} = \mathbf{P}_k^- \mathbf{C}^T (\mathbf{C} \mathbf{P}_k^- \mathbf{C}^T + \mathbf{R})^{-1}. \quad (4.69)$$

Der Innovationsschritt verknüpft nun die Messung \mathbf{z}_k und die Prädiktion $\hat{\mathbf{s}}_k^-$ gewichtet zu einer neuen („a posteriori-“) Schätzung:

$$\hat{\mathbf{s}}_k = \hat{\mathbf{s}}_k^- + \mathbf{K}(\mathbf{z}_k - \mathbf{C}\hat{\mathbf{s}}_k^-). \quad (4.70)$$

Die dieser Schätzung zugehörige Fehlerkovarianzmatrix

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}\mathbf{C})\mathbf{P}_k^- \quad (4.71)$$

gibt den Fehler dieser Schätzung an (mit Einheitsmatrix \mathbf{I}). Beide Werte bilden nun die Grundlage für einen erneuten Durchlauf zur Schätzung des nächsten Systemzustands und der Ablauf beginnt im nächsten Zeitschritt von vorn.

Bei einem *Constant Velocity*-Modell, wie im hier beschriebenen PreCrash-System verwendet, kann der Zustandsvektor $\hat{\mathbf{s}}$ beispielsweise aus den folgenden Komponenten bestehen [Wu04, Dol05]:

$$\hat{\mathbf{s}} = \begin{pmatrix} x \\ \dot{x} \\ y \\ \dot{y} \\ \beta \end{pmatrix}, \quad (4.72)$$

mit den x - und y -Komponenten der Position, den jeweiligen Komponenten \dot{x} und \dot{y} des Geschwindigkeitsvektors und dem Orientierungswinkel β des Objekts. Das hierbei verwendete Bewegungsmodell

$$x_k = x_{k-1} + T \cdot v_{x_{k-1}} \quad (4.73)$$

$$v_{x_k} = v_{x_{k-1}} \quad (4.74)$$

$$y_k = y_{k-1} + T \cdot v_{y_{k-1}} \quad (4.75)$$

$$v_{y_k} = v_{y_{k-1}} \quad (4.76)$$

$$\beta_k = \beta_{k-1} \quad (4.77)$$

mit der Zykluszeit T ist in der Zustandsübergangsmatrix \mathbf{A} abgelegt:

$$\mathbf{A} = \begin{pmatrix} 1 & T & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & T & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix}. \quad (4.78)$$

Der Modellfehler bzw. die Prozessfehlerkovarianzmatrix \mathbf{Q} ist durch

$$\mathbf{Q} = E[\tilde{\mathbf{s}}\tilde{\mathbf{s}}^T] \quad (4.79)$$

definiert, wobei $\tilde{\mathbf{s}}$ der bei der Prädiktion entstehende Fehler ist:

$$\tilde{\mathbf{s}} = \mathbf{s} - \hat{\mathbf{s}}^-. \quad (4.80)$$

Die Fehler kommen aufgrund einer ungenauen Beschreibung der Wirklichkeit durch das verwendete Modell zustande; im vorliegenden Beispiel vor allem durch die nicht berücksichtigte Beschleunigung. Die Abschätzung der Fehler erfolgt unter Verwendung der 3σ -Methode, bei der sich unter der Voraussetzung einer Gauß-Verteilung die Standardabweichung bzw. die Varianz des Fehlers herleiten lässt. Grundlage dafür ist die Annahme, dass sich ein Wert mit einer Wahrscheinlichkeit von 99,73% im Bereich

$$\mu - 3\sigma \leq s_i \leq \mu + 3\sigma \quad \text{mit} \quad \mu = E[\tilde{s}_i] = 0 \quad (4.81)$$

befindet. Die Grenzen $\mu - 3\sigma$ und $\mu + 3\sigma$ sind beispielsweise bei der x -Position mit

$$x = \frac{1}{2}aT^2 \quad (4.82)$$

und entsprechend Gleichung 4.79 mit

$$E[\tilde{x}\tilde{x}] = E\left[\left(\frac{1}{2}aT^2\right)^2\right] = \frac{1}{4}t^4 E[a^2] = \frac{1}{4}t^4 \sigma_a^2 \quad (4.83)$$

aus den maximal zu erwartenden Beschleunigungen a der beobachteten Objekte abzuleiten. Mit Hilfe der Standardabweichung der Zustandskomponenten s_i

$$\sigma_{s_i} = \frac{1}{3}(s_{i,max} - \mu) = \frac{1}{3}a \quad (4.84)$$

lässt sich dann das Element der Prozessfehlerkovarianzmatrix mittels

$$Q_{ij} = E[\tilde{s}_i\tilde{s}_j] \approx \frac{1}{3}(s_{i,max} - \mu)\frac{1}{3}(s_{j,max} - \mu) \quad (4.85)$$

berechnen. Mit

$$\mathbf{Q} = \begin{pmatrix} E[\tilde{x}\tilde{x}] & E[\tilde{x}\tilde{v}_x] & 0 & 0 & 0 \\ E[\tilde{x}\tilde{v}_x] & E[\tilde{v}_x\tilde{v}_x] & 0 & 0 & 0 \\ 0 & 0 & E[\tilde{y}\tilde{y}] & E[\tilde{y}\tilde{v}_y] & 0 \\ 0 & 0 & E[\tilde{y}\tilde{v}_y] & E[\tilde{v}_y\tilde{v}_y] & 0 \\ 0 & 0 & 0 & 0 & E[\tilde{\beta}^2] \end{pmatrix} \quad (4.86)$$

und

$$E[\tilde{x}\tilde{x}] = E\left[\left(\frac{1}{2}a_xT^2\right)^2\right] = \frac{1}{4}T^4E[a_x^2] \quad (4.87)$$

$$E[\tilde{v}_x\tilde{v}_x] = E[(a_xT)^2] = T^2E[a_x^2] \quad (4.88)$$

$$E[\tilde{y}\tilde{y}] = E\left[\left(\frac{1}{2}a_yT^2\right)^2\right] = \frac{1}{4}T^4E[a_y^2] \quad (4.89)$$

$$E[\tilde{v}_y\tilde{v}_y] = E[(a_yT)^2] = T^2E[a_y^2] \quad (4.90)$$

$$E[\tilde{x}\tilde{v}_x] = E\left[\frac{1}{2}a_xT^2 \cdot a_xT\right] = \frac{1}{2}T^3E[a_x^2] \quad (4.91)$$

$$E[\tilde{y}\tilde{v}_y] = E\left[\frac{1}{2}a_yT^2 \cdot a_yT\right] = \frac{1}{2}T^3E[a_y^2] \quad (4.92)$$

$$E[\tilde{\beta}\tilde{\beta}] = E[(v_\beta T)^2] = T^2E[v_\beta^2] \quad (4.93)$$

ergibt sich schließlich die folgende Prozessfehlerkovarianzmatrix:

$$\mathbf{Q} = \begin{pmatrix} \frac{1}{4}T^4E[a_x^2] & \frac{1}{2}T^3E[a_x^2] & 0 & 0 & 0 \\ \frac{1}{2}T^3E[a_x^2] & T^2E[a_x^2] & 0 & 0 & 0 \\ 0 & 0 & \frac{1}{4}T^4E[a_y^2] & \frac{1}{2}T^3E[a_y^2] & 0 \\ 0 & 0 & \frac{1}{2}T^3E[a_y^2] & T^2E[a_y^2] & 0 \\ 0 & 0 & 0 & 0 & T^2E[v_\beta^2] \end{pmatrix}. \quad (4.94)$$

Die Messfehlerkovarianzmatrix \mathbf{R} enthält bei voneinander unabhängigen Elementen des Messvektors

$$\mathbf{z} = \begin{pmatrix} x \\ y \\ \beta \end{pmatrix} \quad (4.95)$$

nur Diagonalelemente mit den jeweiligen Messunsicherheiten:

$$\mathbf{R} = \begin{pmatrix} \sigma_x^2 & 0 & 0 \\ 0 & \sigma_y^2 & 0 \\ 0 & 0 & \sigma_\beta^2 \end{pmatrix}. \quad (4.96)$$

Die Messmatrix \mathbf{C} lautet:

$$\mathbf{C} = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix}. \quad (4.97)$$

Da die Elemente des Messvektors aufgrund der Merkmalsextraktion innerhalb der Segmentierungsstufe des Laserscanners nicht unabhängig voneinander sind, ergibt sich aus der Annahme der Unabhängigkeit ein Fehler⁴.

⁴Die Verwendung adaptiver Kovarianzmatrizen (vgl. Abschnitt 4.3.4) macht diesen Fehler vernachlässigbar.

4.3.3 Assoziation

Der Assoziationsschritt als Teil des Tracking hat die Aufgabe, bestehenden Prädiktionen \hat{s}_k^- Messungen \mathbf{z}_k des aktuellen Zyklus zuzuordnen. Dieser Teil des Trackings enthält Methoden zur Bestimmung eines Suchbereiches (*Gating*), zur Zuordnung (*Association*), zur Erzeugung eines Tracks (*Track Initiation*), zur Bestätigung des Tracks (*Track Confirmation*) und zum Löschen des Tracks (*Track Deletion*) [BP99]. Für die Umsetzung der einzelnen Schritte existiert eine Vielzahl an unterschiedlichen Verfahren. Einige, für die Anwendung relevante Vertreter von Gating-, Zuordnungs- und Verwaltungsverfahren für *Single-Hypothesis-Tracking* sind in den folgenden Abschnitten kurz beschrieben.

Verwaltung von Tracks

Zur Verwaltung von Tracks gehört die Steuerung des gesamten Assoziationsschrittes, was vor allem die Organisation von Track-Zuständen bzw. deren Übergänge beinhaltet. Mit Hilfe von Track-Zuständen lassen sich die Erzeugung, Bestätigung, das Löschen und auch das Bewerten von Tracks einfach umsetzen. Mögliche Zustände für das Tracking-Filter im vorgestellten PreCrash-System sind zum Beispiel [Wu04]:

- **INIT** Dies ist der erste Zustand eines neuen Objekts. Das Objekt entsteht aus einer Messung, die keinem existierenden Track zugeordnet ist.
- **TENTATIVE** Neu aufgesetzte Tracks, denen eine Messung in ihrem zweiten Lebenszyklus zugeordnet werden kann, erhalten diesen Status.
- **CONFIRMED** Nach mehrfacher Zuordnung einer Messung zu einem Track kommt der Track in diesen Status, der eine aufgrund der Lebensdauer ausreichend stabile Schätzung anzeigt.
- **MISSED** Bei fehlender zuordenbaren Messung erhält ein Track diesen Zustand, der schon eine Vorauswahl bzw. Kandidatenliste zu löschender Objekte darstellt.
- **DEAD** Nach mehrfach fehlender Zuordenbarkeit einer Messung zu einem Track löscht die Zustandsverwaltung diesen Track.

Ein Beispiel für entsprechende Zustandsübergänge ist in Abbildung 4.14 in Form eines Automatengraphen dargestellt.

Bestimmung des Suchbereiches

Die Festlegung eines Suchbereiches bzw. das „Gating“ ist eine Technik zur Eliminierung unwahrscheinlicher Paare, die aus einem Track und einer Messung bestehen [BP99]. Das wichtigste Ziel ist dabei die Reduktion des Rechenaufwands bei der Suche nach der wahrscheinlichsten Zuordnung. Das Gate sollte gerade so groß sein, dass eine zugehörige Messung nicht verloren geht, jedoch so klein, dass keine unwahrscheinlichen Messungen berücksichtigt und bei einem zeitweisen Ausfall der eigentlich zugehörigen Messung fälschlicherweise zugeordnet werden.

Eines der einfachsten Gating-Verfahren ist die Verwendung eines rechteckigen Suchbereiches. Unter Einbeziehung statistischer Informationen über den bereits existierenden Track und die




Abbildung 4.14: Zustandsübergänge für Track-Zustände

vorliegenden Messungen bietet sich jedoch die Methode des *statistischen Gates* an. Hierbei sind für die Zuordnung nur Messungen x_M, y_M zu berücksichtigen, für die gilt:

$$D^2 = \frac{(x_P - x_M)^2}{\sigma_x^2} + \frac{(y_P - y_M)^2}{\sigma_y^2} \leq 1. \quad (4.98)$$

Die Werte x_P und y_P entsprechen den prädierten Positionswerten aus Gleichung 4.66. Die das Gate formenden Unsicherheiten der Positionsbestimmung sind in σ_x^2 und σ_y^2 abgelegt. Diese Unsicherheiten leiten sich aus den Messfehlern $\sigma_{y,M}^2$ und $\sigma_{x,M}^2$ und dem geschätzten Fehler für die jeweiligen Positionswerte bei der Prädiktion $\sigma_{y,P}^2$ und $\sigma_{x,P}^2$ aus Gleichung 4.67 ab:

$$\sigma_x^2 = \sigma_{x,P}^2 + \sigma_{x,M}^2 \quad (4.99)$$

$$\sigma_y^2 = \sigma_{y,P}^2 + \sigma_{y,M}^2. \quad (4.100)$$

Die Anwendung eines solchen Gate zur Filterung unwahrscheinlicher Track-Messung-Zuordnungen ist nicht zwingend auf Positionswerte beschränkt. Auch Merkmale wie die Abmessung oder die Lage eines Objekts bzw. der als Segment vorliegenden Messung kann dem Ausschluss von Paaren nach dem obig beschriebenen Verfahren dienen.

Zuordnung

Zuordnungsverfahren entscheiden, welche nach dem Gating noch vorhandene Paare letztendlich miteinander zu kombinieren sind. Zur Realisierung solcher Verfahren existieren viele

Ansätze. Ein wichtiges Unterscheidungskriterium für diese Ansätze ist die maximale Anzahl an Messungen, die sie einem Track zuordnen. Weiterhin lassen sich Zuordnungsverfahren in deterministische und wahrscheinlichkeitsbasierte Verfahren unterscheiden. Letztere produzieren Mehrfach-Hypothesen. Dies bedeutet nichts anderes als die Zuordnung aller N Messungen $\mathbf{z}_{i,j,k}$ (*All-Neighbors Data Association*) zum Zeitpunkt k unter Verwendung von Gewichtungsfaktoren $w_{i,j}$ zum Track i :

$$\mathbf{z}_{i,k} = \sum_{j=1}^N w_{i,j} \mathbf{z}_{i,j,k}. \quad (4.101)$$

Bekannte Vertreter sind sowohl *PDA*- (Probabilistic Data Association) als auch das *JPDA*-Verfahren (Joint Probabilistic Data Association) [BP99].

Eine sehr weit verbreitete, aber aufgrund der Zuordnung von nur einer Messung zu einem Track für das vorgestellte PreCrash-System wesentlich geeignetere Methode ist das *Global-Nearest-Neighbor*-Verfahren. Dieser Algorithmus behandelt nur die wahrscheinlichste Hypothese, was dem Paar, bestehend aus Track und Messung, mit dem kleinsten D_i^2 nach Gleichung 4.98 entspricht. Im Gegensatz zu wahrscheinlichkeitsbasierten Verfahren kommt es hier jedoch zum Auftreten von Konfliktfällen, wenn Messungen innerhalb der Gates mehrerer Tracks liegen. Derartige Konfliktfälle sind dann durch verschiedene Strategien wie zum Beispiel

- die Einbeziehung der Track-Zustände bei der Ermittlung der Priorität der jeweiligen Tracks,
- der Einbeziehung weiterer Merkmale (Abmessungen, Orientierungswinkel),
- die Entscheidung nach dem kleinsten $D_{i,j}^2$

oder durch die Kombination dieser Strategien aufzulösen. Eine – allerdings rechenaufwendige – Alternative hierzu stellen Auktionsalgorithmen dar, deren Ziel die Maximierung des „Gesamtgewinns“ mit Hilfe einer Zuordnungsmatrix ist [BP99].

4.3.4 Erweiterungen

Start eines Tracks

Das Kalman-Filter schätzt den aktuellen Zustand unter Einbeziehung des alten Zustandes mittels Prädiktion und einer aktuellen Messung. Beim Start eines neuen Tracks ist jedoch kein vorhergehender Zustand vorhanden, was eine *a priori*-Annahme notwendig machen würde. Eine solche Annahme hat jedoch aufgrund des fehlenden *a priori*-Wissens in den allermeisten Fällen einen großen Abstand zum realen Startpunkt, was innerhalb der ersten Tracking-Zyklen zu großen Schätzfehlern führt.

Ziel muss jedoch sein, die Anzahl der benötigten Zyklen vom Aufsetzen eines neuen Tracks bis zur Verfügbarkeit stabiler Schätzungen so klein wie möglich zu halten, um eine schnelle Reaktionszeit des Systems und den Betrieb auch bei hohen Geschwindigkeiten und vorgegebener Sensorreichweite (siehe Abschnitt 1.4) zu garantieren.

Die Lösung für dieses Problem stellt die Verwendung des physikalischen Modells der konstanten Geschwindigkeit für die ersten beiden Track-Zyklen anstelle des Kalman-Filters dar:

$$\mathbf{x}_k = \mathbf{C} \cdot \mathbf{z}_k \quad (4.102)$$

$$\mathbf{x}_{k+1} = \mathbf{C} \cdot \mathbf{z}_{k+1} \quad (4.103)$$

$$\mathbf{x}_{k+1} = \frac{\mathbf{C}_{x,y} \mathbf{z}_{k+1} - \mathbf{C}_{x,y} \mathbf{z}_k}{T}, \quad (4.104)$$

mit

$$\mathbf{C}_{x,y} = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{pmatrix}. \quad (4.105)$$

Das Aufsetzen des Kalman-Filters im dritten Zyklus geschieht nun unter Verwendung der so errechneten Werte.

Eigenbewegungskompensation

Die erwarteten Ungenauigkeiten bei der Bestimmung einer Prädiktion $\hat{\mathbf{s}}_k^-$, die die Prozessfehlerkovarianzmatrix \mathbf{Q} repräsentiert, sind nicht nur Folge der Abweichungen der Objektbewegungen von dem zugrunde gelegten Modell, sondern auch eine Folge der durch die Bewegung des eigenen Fahrzeugs hervorgerufenen Abweichungen. Moderne Fahrzeuge liefern ständig Informationen wie zum Beispiel Raddrehzahlen, Lenkradwinkel oder Gierrate, die unter Verwendung geeigneter Bewegungsmodelle [Zom91] der Schätzung der durch die Eigenbewegung hervorgerufenen Positionsänderung dienen können. Das Tracking-Filter kann diese Positionsänderung Δx und Δy bei der Prädiktion der neuen Objektposition berücksichtigen. Vermiedene oder verringerte Einflüsse durch die Eigenbewegung bedeuten eine geringere Abweichung vom angenommenen Bewegungsmodell, verbessern so die Qualität der Schätzung $\hat{\mathbf{s}}_k$ und können damit auch bei der Wahl der Parameter für \mathbf{Q} Berücksichtigung finden.

Die Eigenbewegungskompensation kann aber angesichts der Anwendung hier nicht so ohne weiteres zum Einsatz kommen, da Aussagen bezüglich der Eigenbewegung des Fahrzeugs gerade in kritischen Situationen (z. B. Schleudern) nicht mit ausreichender Genauigkeit und Sicherheit vorliegen. Das vorgestellte PreCrash-System soll aber gerade in Situationen verlässliche Aussagen liefern, die sich zeitlich kurz vor einem Unfall befinden und damit sehr oft mit instabilen Fahrzeugzuständen verbunden sind.

Adaptive Kovarianzmatrizen

Die Beschreibung des Objektverhaltens durch ein Modell hat, wie in den vorherigen Abschnitten bereits angesprochen, gewisse Defizite. Das Modell bzw. seine Parametrisierung ist meist für den ungünstigsten Fall (zum Beispiel starke Beschleunigungen) ausgelegt. Das Verhalten der meisten Objekte entspricht aber nicht dieser Annahme. Dies führt zu großen Prozess(ko)varianzen in \mathbf{Q} und damit zu einer in vielen Fällen ungenügenden Glättung durch das Kalman-Filter bzw. einer Vergrößerung des Schätzfehlers. Neben der parallelen Beobachtung des Objektverhaltens durch mehrere Modelle (*Mehr-Modell-Ansatz*) kann die Anpassung des Filters an das Objektverhalten auch über die Veränderung der im Modell berücksichtigten

Varianz des Systemrauschens erfolgen [Bec02, Dol05]. Letztere Lösung bietet sich aufgrund ihrer Einfachheit und den geringen Anforderungen an Rechenleistung und Speichermenge für den Einsatz in einem Umfelderkennungssystem im Automobilbereich besonders an.

Eine grundlegende Aufgabe bei der Adaption der Prozessfehlerkovarianzmatrix \mathbf{Q} ist die Erkennung der Abweichung des Objektverhaltens vom Modellverhalten, auch als *Manöverdetektion* bezeichnet [Bec02]. Im vorliegenden System geschieht diese Abweichung vor allem durch Beschleunigungsvorgänge der beobachteten Objekte oder des eigenen Fahrzeugs (des Beobachters). Zur Erkennung von Abweichungen lässt sich die *normierte quadratische Innovation* nutzen:

$$\epsilon_k = (\boldsymbol{\nu} - \bar{\boldsymbol{\nu}})^T \mathbf{S}^{-1} (\boldsymbol{\nu} - \bar{\boldsymbol{\nu}}). \quad (4.106)$$

Dabei ist \mathbf{S} die Innovationskovarianzmatrix (siehe auch Gl. 4.110 und 4.111) und $\bar{\boldsymbol{\nu}}$ der Mittelwert der Innovation $\boldsymbol{\nu}$:

$$\boldsymbol{\nu} = \mathbf{K}(\mathbf{z}_k - \mathbf{C} \cdot \hat{\mathbf{s}}_k^-). \quad (4.107)$$

Aufgrund der Erwartungstreue der Schätzwertes ergibt sich

$$\bar{\boldsymbol{\nu}} = 0 \quad (4.108)$$

und damit

$$\epsilon_k = \boldsymbol{\nu}^T \mathbf{S}^{-1} \boldsymbol{\nu}. \quad (4.109)$$

Der Wert ϵ_k stellt dabei einen Indikator dar, der bei einem gut angepassten Bewegungsmodell eine Schwelle ϵ_{max} mit einer definierten Wahrscheinlichkeit nicht überschreitet. Bei einem Manöver wäre genau dieses der Fall.

Da die Anpassung bei dem verwendeten Modell in beide Koordinatenrichtungen unabhängig voneinander geschehen kann, sind zwei unabhängige quadratische Innovationen zu berechnen:

$$\epsilon_x = \begin{pmatrix} \nu_x \\ \nu_{v_x} \end{pmatrix}^T \begin{pmatrix} S_{xx} & S_{xv_x} \\ S_{xv_x} & S_{v_x v_x} \end{pmatrix}^{-1} \begin{pmatrix} \nu_x \\ \nu_{v_x} \end{pmatrix} \quad (4.110)$$

$$\epsilon_y = \begin{pmatrix} \nu_y \\ \nu_{v_y} \end{pmatrix}^T \begin{pmatrix} S_{yy} & S_{yv_y} \\ S_{yv_y} & S_{v_y v_y} \end{pmatrix}^{-1} \begin{pmatrix} \nu_y \\ \nu_{v_y} \end{pmatrix}. \quad (4.111)$$

Die Koeffizienten, das heißt die Varianzen und Kovarianzen der Innovationskovarianzmatrizen \mathbf{S}_x und \mathbf{S}_y , werden aus Histogrammen der einzelnen Komponenten der Innovationsvektoren extrahiert. Die Erstellung dieser Histogramme geschieht dabei mit unveränderter Prozesskovarianzmatrix \mathbf{Q} und mittels Messungen oder Simulationen, die Daten von Objekten enthalten, die sich entsprechend der Modellannahme bewegen.

Mit der Information, ob ein Manöver stattfindet, lassen sich nun die Koeffizienten der Prozessfehlerkovarianzmatrix \mathbf{Q} anpassen. Dabei sind unterschiedliche Varianten denkbar:

- Es kann eine Umschaltung zwischen zwei festen Werten erfolgen.
- Eine Umschaltung über mehrere Stufen zwischen zwei Grenzwerten ist möglich.
- Eine Realisierung mit unterschiedlicher Größe bzw. Anzahl der Stufen, abhängig von der Richtung, verändert die Sensibilität des Filters in Bezug auf Manöver.

Die Wahl des oberen Schwellwertes ϵ_{max} ist durch Auswerten der Statistiken bezüglich der normierten quadratischen Innovation im Falle an das Modell angepasster Objektbewegungen zu treffen. Bei einem gut angepassten Filter sollte ϵ_k diesen Schwellwert nur in maximal 5 % der Fälle überschreiten [BSL93].

Nicht nur die Abweichung des Objektverhaltens vom Modellverhalten, sondern auch die schwankende Qualität der Eingangsdaten bewirkt zusätzliche Fehler bei einer statischen Festlegung der Koeffizienten der Messfehlerkovarianzmatrix \mathbf{R} . Die wichtigste Ursache für eine schwankende Qualität der Eingangsdaten rührt bei der Verwendung eines Laserscanners vor allem aus den geometrischen Eigenschaften des Messverfahrens her. So nimmt die Anzahl an Messpunkten pro Segment stark ab, wenn ein Objekt den Sichtbereich des Sensors verlässt (vgl. Abschnitt 4.2.2). Eine zu große Reduktion der Messpunkteanzahl eines Segments innerhalb einer Zyklusdauer T ist folgerichtig bei der Adaption der Koeffizienten von \mathbf{R} zu berücksichtigen.

4.4 Sensorausfall-Erkennung

Ein wichtiges Kennzeichen eines Umfelderkennungssystems ist die Sicherheit bzw. Qualität der gelieferten Ausgaben oder Entscheidungen. Die Sensorik eines solchen Systems ist oft – wie auch im vorgestellten PreCrash-System – im Frontbereich des Fahrzeuges angebracht. Sie ist damit einer Vielzahl an Einflüssen wie zum Beispiel Schmutz, Regen, Schnee oder Vibrationen ausgesetzt. Diese Einflüsse beeinträchtigen das Sensorsystem unter Umständen und führen damit zu schlechteren Detektionsleistungen bis hin zu einem kompletten Ausfall eines oder mehrerer Sensoren. Das führt in der Regel zu einer Verschlechterung der Leistungen des Gesamtsystems, die dann zumindest für die korrekte Bewertung der Ausgangsdaten bestimmbar sein muss. Bei einer Erkennung verschlechterter Detektionsleistung bietet sich zudem eine Veränderung der Signalverarbeitung, etwa eine Anpassung von Gewichtungsfaktoren, an.

Die folgenden Abschnitte beschreiben typische Arten von Sensorfehlern bzw. -ausfällen in einem solchen Umfelderkennungssystem, geben einen kurzen Überblick zu bekannten Verfahren und stellen ein, speziell an ein Umfelderkennungssystem im Automobilbereich und die verwendeten Sensoren angepasstes, innerhalb der Arbeiten an dem PreCrash-System entwickeltes Verfahren vor.

4.4.1 Fehlerarten

Innerhalb eines Sensorsystems können verschiedene Arten von Fehlern auftreten. Neben dem Komplettausfall eines Sensors, bei dem der Sensor keine oder komplett falsche Daten liefert, kann sich auch die Qualität der Messwerte verschlechtern. So sind zum Beispiel eine Verschlechterung der Detektionsleistungen und der damit verbundenen verschiedenartigen Einschränkungen des Sichtbereiches, größere Messungenauigkeiten (Rauschen) oder der Verlust einzelner Informationsanteile möglich.

Fehler können sich *additiv* oder *multiplikativ* überlagern. Weiterhin ist sowohl *zeitweises* oder *dauerhaftes* Auftreten von Fehlern oder Ausfällen möglich.

Im Falle eines Umfelderkennungssystems im Automobilbereich spielen in erster Linie Fehler

eine Rolle, die aus externen Einflüssen wie zum Beispiel dem Wetter herrühren. Typischerweise führen im Fahrzeugumfeld häufig auftretende Faktoren wie Schmutzablagerungen, Schnee, Nebel oder Regen zu einer verminderten Detektionsleistung bis hin zum „Komplettausfall“. Jegliche Art von im Automobilbereich verwendeter Umfeldsensorik ist von diesen äußeren Einwirkungen mehr oder weniger betroffen.

4.4.2 Bekannte Ansätze zur Fehlererkennung

Die Erkennung von Sensorausfällen oder Systemfehlern war und ist Thema vieler Arbeiten im Bereich der Sensorsignalverarbeitung (z. B. [VRYK03, Fri01, Uzu05b]). Im Laufe der Zeit entstand eine Vielzahl von Ansätzen, die sich in zwei große Gruppen unterscheiden lassen. So nutzt eine Gruppe der Fehlererkennungsverfahren mathematische Modelle des überwachten Systems, während die andere Gruppe auf solche Modelle verzichtet. Abbildung 4.15 gibt




Abbildung 4.15: Überblick zu bekannten Fehlererkennungsverfahren [Uzu05b]

einen Überblick zu den so unterschiedenen Fehlererkennungsverfahren.

Die Beschreibung der überwachten Systeme bzw. deren Verhaltens innerhalb des Zustandsraums stellt vor allem bei der Verwendung modellbasierter Verfahren die Grundlage für die Modellierung des Systems bzw. des Systemverhaltens dar. Eine zeitdiskrete, lineare Beschreibungsform eines Systems im Zustandsraum ist zum Beispiel [VRYK03]

$$\mathbf{s}(k+1) = \mathbf{A}\mathbf{s}(k) + \mathbf{B}\mathbf{u}_k \quad (4.112)$$

$$\mathbf{y}(k) = \mathbf{C}\mathbf{s}(k) + \mathbf{D}\mathbf{u}_k, \quad (4.113)$$

mit den Systemparametermatrizen \mathbf{A} , \mathbf{B} , \mathbf{C} und \mathbf{D} , k als Zeitindex, dem Eingang \mathbf{u}_k , dem Ausgang $\mathbf{y}(k)$ und dem Zustand $\mathbf{s}(k)$. Die Systemgleichung lässt sich ebenso in der Eingang-Ausgang-Form

$$\mathbf{H}(z)\mathbf{y}(k) = \mathbf{G}(z)\mathbf{u}(k) \quad (4.114)$$

mit den Polynommatrizen $\mathbf{G}(z)$ und $\mathbf{H}(z)$ und dem Verschiebungsoperator z angeben [VRYK03]. Multiplikative Fehler sind dann ausgehend von Gleichung 4.114 mit

$$(\mathbf{H}(z) + \Delta\mathbf{H}(z))\mathbf{y}(k) = (\mathbf{G}(z) + \Delta\mathbf{G}(z))\mathbf{u}(k) \quad (4.115)$$

beschreibbar [Ger91]. Hier repräsentieren $\Delta\mathbf{H}(z)$ und $\Delta\mathbf{G}(z)$ die Parametermatrizen bei multiplikativen Fehlern. Daneben sind additive Fehler durch

$$\mathbf{H}(z)\mathbf{y}(k) = \mathbf{G}(z)\mathbf{u}(k) + \mathbf{H}(z)\mathbf{q}(k) + \mathbf{K}(z)\mathbf{w}(k) \quad (4.116)$$

definiert [Ger91]. Dabei sind $\mathbf{q}(k)$ und $\mathbf{w}(k)$ Vektoren, die Sensorfehler bzw. unbekannte Einflüsse beinhalten. Additive Fehler treten als unbekannte, zeitabhängige Funktionen $\mathbf{q}(k)$ und $\mathbf{w}(k)$ mit bekannten Parametermatrizen $\mathbf{H}(z)$ und $\mathbf{K}(z)$ multipliziert auf, während sich multiplikative Fehler als bekannte (beobachtbare), zeitabhängige Funktionen $\mathbf{y}(k)$ und $\mathbf{u}(k)$ mit unbekannten Parametermatrizen $\Delta\mathbf{H}(z)$ und $\Delta\mathbf{G}(z)$ multipliziert präsentieren [VRYK03].

Eine übliche Vorgehensweise zur Erkennung von Fehlern ist das Nutzen von Redundanz. Dabei ist zwischen zwei Arten der Redundanz zu unterscheiden [VRYK03]. Auf der einen Seite steht die *Hardware*-Redundanz. Bei der vorliegenden Aufgabe der Erkennung von Sensorausfällen lässt sich diese durch Einsatz zusätzlicher gleichartiger Sensorik erreichen. Der Vergleich der Sensorausgänge kann Ausfälle einzelner Sensoren aufzeigen. Allerdings erhöht eine solche Lösung den Platzbedarf und den Preis des Gesamtsystems und hat Probleme bei der Erkennung von gleichzeitigen Ausfällen mehrerer Sensoren. Im Unterschied dazu benötigt der Ansatz der *analytischen* Redundanz keine zusätzliche Sensorik. Die „Redundanz“ besteht hier im Wissen über Zusammenhänge zwischen Eingangswerten, Systemzuständen und Ausgangswerten sowie deren Repräsentation durch mathematische Beschreibungen. Diese Art der Redundanz ist wiederum unterscheidbar: *Direkte* Redundanz beruht auf dem Wissen bezüglich der Zusammenhänge zwischen den Ausgaben verschiedener Sensoren, während *zeitliche* Redundanz das Wissen über zukünftige Ausgangswerte in Abhängigkeit von aktuellen Zustands- und Eingangswerten umfasst.

Modellbasierte Verfahren

Modellbasierte Verfahren beruhen auf dem Wissen über die Zusammenhänge zwischen verschiedenen Komponenten eines Systems (analytische Redundanz). Diese Zusammenhänge sind mathematisch beschreibbar. Der Vergleich der Ausgangswerte der mathematischen Modelle mit den aktuellen Messwerten, auch bekannt als *Residuen*, lässt dann Rückschlüsse auf die Arbeit des überwachten Systems zu (Abbildung 4.16). Residuen sind im Idealfall, das heißt bei Abwesenheit von Rauschen und Modellfehlern Null, wenn kein Fehler vorliegt [Fri01]. Die aber in realen Systemen auftretenden Abweichungen durch Modellfehler oder Rauschen sind im einfachsten Falle mittels Schwellwerten zu überprüfen [ger98].

Für die Umsetzung modellbasierter Fehlererkennung bieten sich die auf Schätzverfahren beruhenden und in [Fri01, VRYK03, Uzu05b] beschriebenen Varianten wie zum Beispiel

- Parameter Estimation
- State Observer
- Parity Equations

an. Als Schätzverfahren kommen häufig Kalman-Filter zum Einsatz.




Abbildung 4.16: Allgemeine Struktur modellbasierter Fehlererkennungsverfahren [Uzu05b]

Modellbasierte Verfahren zur Erkennung von Sensorausfällen sind jedoch bei der gegebenen Anwendung kaum einsetzbar. Zum einen ist das Umfeld eines Fahrzeugs extrem variabel, sodass sich kaum Modelle entwickeln lassen. Zum anderen sind auch die Eingangswerte – also die reale bzw. erwartete Umgebung – völlig unbekannt. Hinzu kommt ein recht hoher Implementations- und Rechenaufwand.

Modellfreie Verfahren

Es existiert eine Vielzahl von Verfahren, die ohne die Nutzung mathematischer Modelle Fehler erkennen können. Solche Verfahren basieren oft auf der Auswertung der Daten, die innerhalb eines festgelegten Zeitbereiches angefallen sind. Typische Vertreter solcher Verfahren sind Klassifikatoren oder statistische Verfahren, die Trends erkennen können. Andere Ansätze bestehen in der Bestimmung statistischer Merkmale, die auf eine Vergrößerung des Sensorrauschens schließen lassen. Auch ist die Untersuchung, ob sich Ausgangswerte innerhalb bestimmter Grenzen befinden, möglich. Ein einfaches Beispiel für eine solche Grenze stellt der folgende Ausdruck dar [Uzu05b]:

$$|x(k) - x(k-1)|_{\max} = v_{\text{rel},\max} \cdot T + \frac{1}{2} a_{\text{rel},\max} T^2. \quad (4.117)$$

So kann der Unterschied in einer Distanzmessung nicht größer als ein Wert sein, der sich aus der Messzykluszeit T , der maximalen Geschwindigkeit eines beobachteten Objekts $v_{\text{rel},\max}$ und der maximal möglichen Beschleunigung $a_{\text{rel},\max}$ ergibt.

In besonders sicherheitskritischen Bereichen ist die Nutzung von Hardware-Redundanz zur Fehlererkennung und -behebung die Regel.

Alle diese Verfahren können nur ganz bestimmte Fehler finden oder basieren auf der Verwendung zusätzlicher Sensorik und verursachen damit einen Mehraufwand. Zudem benötigen sie, beispielsweise bei der Bestimmung des Rauschverhaltens, nicht selten Informationen, die am Ausgang vieler Sensoren nicht mehr zur Verfügung stehen.

4.4.3 Stochastisches Verfahren zur Fehlererkennung

Die in den vorherigen Abschnitten aufgeführten Mängel typischer und bekannter Fehlererkennungsverfahren machte die Entwicklung eines eigenen Verfahrens notwendig, welches

- nicht auf Modellannahmen basiert,
- keine speziellen, sensorinternen Informationen benötigt,
- unabhängig vom Wissen über die reale Situation im Umfeld des Fahrzeuges funktioniert,
- nur zum Teil Hardware-Redundanz benötigt,
- die Daten unterschiedlicher Sensoren mit benachbarten oder gleichen Sichtbereichen berücksichtigen kann,
- sensorunabhängig ist,
- den gleichzeitigen Ausfall mehrerer Sensoren detektieren kann,
- sehr einfach ist und
- die im Fahrzeugbereich typischen Einschränkungen der Detektionsleistungen durch Verschmutzung oder Wettereinflüsse erkennen kann.

Das hierfür entwickelte Verfahren ist den modellfreien Verfahren zuzuordnen und wertet die Daten aus, die innerhalb eines Zeitintervalls angefallen sind [SLWA05]:

Als Grundlage ist ein geeignetes Zeitfenster F zu definieren. Alle n *Messereignisse*⁵ aller m Sensoren innerhalb dieses Zeitfensters werden nun addiert und der arithmetische Mittelwert berechnet:

$$\mu_m(F) = \frac{1}{m \cdot F} \sum_{i=k}^{k+F} \sum_{j=1}^m n_{ij}. \quad (4.118)$$

Das Ergebnis dieser Berechnung ist die durchschnittliche Anzahl von Messereignissen für einen Zeitpunkt i bezogen auf einen einzelnen Sensor. Dieser Zeitpunkt kann aber ebenso durch ein Zeitintervall T repräsentiert sein:

$$T \ll F. \quad (4.119)$$

Der nächste Schritt beinhaltet die Berechnung der durchschnittlichen Anzahl von Messereignissen unter Betrachtung eines einzelnen Sensors j :

$$\mu_j(F) = \frac{1}{F} \sum_{i=k}^{k+F} n_{ij}. \quad (4.120)$$

⁵Der Begriff *Messereignisse* umfasst in diesem Zusammenhang alle Ausgaben eines Sensors, die auf die Detektion eines Ziels hindeuten.

4 Einzelsignalverarbeitung der für die Fusion genutzten Sensortypen

Liegt nun das Resultat $\mu_j(F)$ unterhalb eines auf den Durchschnittswert $\mu_m(F)$ aller Sensoren bezogenen Schwellwertes S_{μ_j}

$$\mu_j(F) < \frac{\mu_m(F)}{S_{\mu_j}}, \quad (4.121)$$

so liegt eine Verschlechterung der Detektionsleistung des Sensors i vor. Diese Aussage ist jedoch nur gültig, wenn einige Voraussetzungen gegeben sind:

$$v_{eigen} > v_s \quad \wedge \quad \mu_m(F) > S_{\mu_m}. \quad (4.122)$$

Die Eigengeschwindigkeit v_{eigen} muss über einer bestimmten Schwelle v_s liegen, um den Aufbau einer Statistik zu ermöglichen, bei der durch die Bewegung der Objekte durch die Sichtbereiche der Sensoren eine gleichförmige Verteilung entsteht. Für eine zuverlässige Bestimmung der Detektionsleistung ist zudem eine minimale durchschnittliche Anzahl $\mu_m(F)$ von Messereignissen notwendig (Schwelle S_{μ_m}), die durch Einbeziehung aller Sensoren bestimmt wird. Mit diesem Ansatz ist es möglich, auch verschiedene Sensoren gleichzeitig einzubeziehen. In Fällen unterschiedlicher „typischer“ Anzahlen von Messereignissen bei der Detektion eines Ziels sind die Gleichungen 4.118 und 4.120 durch einen sensorspezifischen Wichtungsfaktor w_j zu erweitern:

$$\mu_m(F) = \frac{1}{m \cdot F} \sum_{i=k}^{k+F} \sum_{j=1}^m w_j n_{ij} \quad (4.123)$$

$$\mu_j(F) = \frac{1}{F} \sum_{i=k}^{k+F} w_j n_{ij}. \quad (4.124)$$

Die Grundidee des Algorithmus' ist in Abbildung 4.17 veranschaulicht.




Abbildung 4.17: Grundidee des Fehlererkennungsverfahrens [Uzu05b]

In die Entscheidung, ob ein Sensorausfall bzw. eine Einschränkung der Detektionsfähigkeit vorliegt, können natürlich zur Erhöhung der Zuverlässigkeit auch die Ergebnisse mehrerer solcher Durchläufe einfließen. Bei jedem Vergleich des Wertes $\mu_j(F)$ mit der Schwelle $\mu_m(F)/S_{\mu_j}$

entsprechend Gleichung 4.121 verändert sich dann ein Ausfallzähler durch

$$d_k = \begin{cases} d_k - c_c & \text{für } \mu_j(F) \geq \frac{\mu_m(F)}{S_{\mu_j}} \wedge d_k > 0 \\ d_k + c_p & \text{für } \mu_j(F) < \frac{\mu_m(F)}{S_{\mu_j}} \wedge d_k < d_{k,max} \end{cases} \quad (4.125)$$

mit der Konstanten c_c , die bei Erfüllung des Kriteriums in Gleichung 4.121 den Ausfallzähler d_k verringert und der Konstante c_p , die d_k bei Unterschreitung des Grenzwertes erhöht. Die endgültige Entscheidung bezüglich eines Sensorausfalls trifft der Algorithmus nach der Überschreitung eines entsprechenden Schwellwertes η durch d_k . Die hierfür minimal benötigte Anzahl an Zyklen k_k

$$k_k : \min(i : \sum_i c_p \leq \eta) \quad (4.126)$$

ist ein Maß für die Sensibilität des Algorithmus.

Die Länge eines Zeitfensters F bestimmt maßgeblich die Qualität der erzeugten Statistik. Zu große Fenster führen zu tragem Verhalten des Entscheidungsalgorithmus und verringern zudem die Anzahl „verwertbarer Fenster“ in Situationen, in denen die in Gleichung 4.122 beschriebenen Voraussetzungen nicht erfüllt werden. Zu kurze Zeitfenster verhindern jedoch den Aufbau einer verlässlichen Statistik. Aufgrund der Tatsache, dass die meisten detektierten Objekte im Umfeld eines Fahrzeuges statische Objekte sind, bietet sich eine von der Fahrzeuggeschwindigkeit abhängige Festlegung der benötigten Fensterbreite F mit entsprechenden Grenzwerten an (Abbildung 4.18).

Eine schnelle, aber dennoch sichere Entscheidung ist aufgrund dieser Zusammenhänge bei




Abbildung 4.18: Fensterbreite abhängig von der (Eigen-)Geschwindigkeit


möglichst kurzen, gerade noch ausreichend langen Zeitfenstern und mehreren, in die endgültige Entscheidung einfließenden Durchläufen zu erwarten.

Bei der Einbeziehung mehrerer Durchläufe besteht der naheliegendste Ansatz in der rein sequentiell getrennten Bestimmung der Werte $\mu_m(F)$ und $\mu_j(F)$ (obere Darstellung in Abbildung 4.19). Dies kann bei ungünstigen Übergängen zu abrupten Änderungen der $\mu_j(F)$ und damit zu fehlerhaften Entscheidungen führen. Eine Variante, die solche abrupten Änderungen vermeiden bzw. vermindern kann, besteht in der Verwendung eines überlappenden Überganges

$$\mu_m(F)_k = \sum_{i=F \cdot (k-1)+1}^{k \cdot F} n[i - (k-1) \cdot \xi \cdot F] \quad (4.127)$$

4 Einzelsignalverarbeitung der für die Fusion genutzten Sensortypen

sequentiell:



überlappend:




Abbildung 4.19: Anordnung der Zeitfenster

mit dem Fensterindex k , dem Zeitindex i und dem Überlappungsfaktor ξ (untere Darstellung in Abbildung 4.19). Der Überlappungsfaktor liegt dabei innerhalb des Intervalls $0 < \xi \leq 1$. Eine weitere Variante bezieht vorhergehende Werte $\mu_m(F)_{k-1}$ gewichtet bei der Bestimmung des aktuellen $\mu_m(F)_k$ ein:

$$\mu_m(F)_k = (1 - \alpha) \cdot \mu_m(F)_{k-1} + \alpha \cdot \mu_m(F)_k. \quad (4.128)$$

Der Gewichtungsfaktor α liegt innerhalb des Intervalls $0 < \alpha \leq 1$ und bestimmt den Anteil, mit dem der Wert $\mu_m(F)_{k-1}$ des letzten Zeitfensters in die Berechnung eingeht.

Das beschriebene Fehlererkennungsverfahren beruht aufgrund des fehlenden Wissens über den aktuellen Zustand des realen Fahrzeugumfelds und der Schwierigkeit, bei der Vielzahl möglicher Objekte im Fahrzeugumfeld verwertbare Modelle aufzustellen, auf dem Vergleich der Daten mehrerer Sensoren. Diese Sensoren müssen nicht zwingend auch physisch unterschiedliche Sensoren sein. So kann beispielsweise bei Sensoren wie dem Laserscanner auch




Abbildung 4.20: Unterteilung des Sichtbereiches in virtuelle Sensoren

eine Unterteilung des Sichtfeldes in *virtuelle Sensoren* erfolgen, mit der dann der durch Verschmutzung verursachte Ausfall bestimmter Winkelbereiche⁶ detektierbar ist (Abb. 4.20).

⁶Die Verschmutzung betrifft die Abdeckung des Sensors, deren Größe (und damit der Möglichkeit, dass nur einzelne Winkelbereiche von Verschmutzung betroffen sind) von Einbautiefe des Sensors und dem benötigten Öffnungswinkel abhängig ist.

Die zusätzliche Zusammenfassung der so entstandenen virtuellen Sensoren zu Gruppen bzw. Unterbereichen schafft eine Voraussetzung für die getrennte Untersuchung größerer Winkelbereiche und vermeidet eine zu große räumliche Distanz zwischen den Sichtbereichen der untersuchten virtuellen Sensoren. Zudem bietet eine solche Lösung einen Ansatz, den Ausfall mehrerer virtueller Sensoren bzw. Winkelbereiche unabhängig voneinander zu detektieren.

5 Fusionsansätze

Im Folgenden wird auf mögliche und zumeist bekannte Verfahren zur Fusion von Daten beider Sensoren eingegangen. Die beschriebenen Ansätze beschränken sich in diesem Kapitel ausschließlich auf die Fusion von Zustandsinformationen. Ein anderer Bereich, die Fusion von Hypothesen, ist dann unter anderem Inhalt des Kapitels 6. Bei der Beschreibung von Fusionsansätzen innerhalb dieses Kapitels stehen Architektur, Realisierbarkeit, Eignung für die gegebenen Rahmenbedingungen sowie die spezifischen Vor- und Nachteile im Vordergrund. Weiterhin befindet sich hier die Beschreibung der letztendlich für die Realisierung des PreCrash-Systems verwendeten Verfahren. Der Abschnitt beginnt mit einem wichtigen Aspekt der Sensordatenfusion: die zeitlichen Faktoren eines solchen Multisensorsystems.

5.1 Zeitliche Aspekte der Signalverarbeitung

Problem

Bei der Fusion von Daten unterschiedlicher Sensoren besteht nicht selten das Problem, dass die unterschiedlichen Sensoren zeitlich nicht synchronisierbar sind. So bestimmen oft mechanische Elemente in den Sensoren den jeweiligen Zeitpunkt und die Dauer der Abtastung. Nachgeschaltete Verarbeitungsstufen, inklusive der notwendigen Verbindungen zwischen verschiedenen Elementen des Systems, benötigen ebenfalls Zeit zur Verarbeitung und zum Transport der Daten. Abbildung 5.1 zeigt die Verbindungen inklusive der teilweise unbekannten Zeitcharakteristiken der verschiedenen Sensoren und Rechner innerhalb des verwendeten Versuchssystems.

Bei einer Fusion von Messdaten verschiedener Sensoren und der damit verbundenen Zu-




Abbildung 5.1: Zeitcharakteristik im Versuchssystem

ordnungs- und Verknüpfungsprobleme ist es notwendig, auch diese Aspekte zu betrachten. Dieser Abschnitt stellt einige wichtige Begriffe, Probleme und Zusammenhänge vor, die mit zeitlichen Aspekten zusammenhängen.

Der Zeitbegriff

Wichtige Größen zur Repräsentation von Zeit sind *Zeitpunkt* und *Intervall* [Klu00]. Ein Intervall begrenzen zwei Zeitpunkte – der Anfangszeitpunkt t_a und der Endzeitpunkt t_e oder der Anfangszeitpunkt t_a und die Dauer T . Die Zeitpunkte können hierbei *absolut* oder *relativ* sein. Absolute Zeitpunkte sind fest in der realen Zeit verankert und eindeutig. Die Angabe dieser Zeitpunkte erfolgt in der Regel nicht durch die Angabe von Jahr, Monat, Tag, Stunde und ähnlichen Begriffen, sondern mit Hilfe eines einzigen Zeitwertes t_p . Dieser Zeitwert ist auf einen diskreten Startzeitpunkt bezogen und mit einer Einheit versehen.

Relative Zeitpunkte beziehen sich auf andere Zeitpunkte. Im Gegensatz zu absoluten Zeitpunkten lassen diese sich mitteln, aufaddieren und vervielfachen.

Die Einteilung in absolut und relativ lässt sich ebenfalls auf Intervalle anwenden. Die Verwendung absoluter bzw. relativer Zeitpunkte zur Begrenzung der Intervalle bestimmt die Unterscheidung. Eine dritte Gruppe stellen die *speziellen Intervalle* dar: Offene Intervalle oder Intervalle wie *immer* oder *nie*.

Eine Einheit ist fester Bestandteil jeglicher Zeitangabe.

Zeitliche Einzelaspekte

Wichtig bei der Verarbeitung und Verknüpfung der Sensordaten ist die Betrachtung der zeitlichen Aspekte der Messung und der Signalverarbeitung der jeweiligen Sensoren und Signalverarbeitungsabschnitten. Die Daten der verschiedenen Sensoren müssen bei der Fusion möglichst exakt aufeinander abgestimmt werden. Zudem ist die Information über das Alter der Messdaten für nachgeschaltete Entscheidungsebenen sehr wichtig. In Anlehnung an [Klu00] sind folgende Zeitaspekte für eine Fusion von Sensordaten zur Umgebungserfassung bestimmend:

Zeitraster des Verarbeitungssystems In der Regel findet die Signalverarbeitung für Umfelderkennungssysteme in Rechnersystemen statt. Diese Rechnersysteme sind in ihrer Verarbeitung an diskrete Zeitpunkte gebunden. Die Basis für diese Zeitpunkte stellt die Taktfrequenz der CPU dar. In Echtzeitsystemen ist die Bearbeitung in verschiedene Prozesse unterteilt. Jeder Prozess besitzt sein eigenes Zeitintervall T_{zp} (Verarbeitungsdauer), welcher wiederum relativ zu einem bestimmten Zeitpunkt t_{ap} eines globalen Intervalls befindet (entspricht der Frequenz der Aufrufe).

Echtzeit-Rechnersysteme machen eine synchrone Verarbeitung durch hinreichend exakte Werte von t_{ap} und T_{zp} realisierbar. Die Verwendung von Nicht-Echtzeit-Rechnersystemen führt in der Regel zu mehr oder minder großen Abweichungen von t_{ap} und T_{zp} . Die Größe der Abweichungen ist nicht vorhersehbar und von Auslastung des Rechners und verwendetem Betriebssystem bzw. dessen Scheduler abhängig. Aufgrund der Abweichungen ermöglichen solche Systeme keine zeitlich definierten Aktionen. Wenn die Messwerte von der Sensorik nicht bei Bedarf sondern kontinuierlich bereitgestellt werden, kann dies unter anderem zum Verlust von Messdaten führen.

Abtastzeitpunkt diskreter Signale Der Abtastzeitpunkt macht die Zuordnung verschiedener Sensordaten bzw. aus ihnen extrahierter Merkmale zueinander und zu realen Objekten innerhalb einer Szene möglich. Aus dem Abtastzeitpunkt lässt sich das Alter der Daten

errechnen und daraus auch eine Relevanz oder Aussagekraft der Messwerte herleiten. In nachgeschalteten Stufen ist das Wissen über die Abtastzeitpunkte bzw. der Bezug zu realen Gegebenheiten für die Festlegung von Zeitpunkten z. B. von Aktionen wichtig. Der Bezug zwischen Zeitbasis des Verarbeitungssystem und der Zeitbasis der Sensorik muss dafür hergestellt sein.

Zeitcharakteristik von Sensoren Die Bereitstellung von Daten durch Sensoren benötigt Zeit. Sensoren können ihre Daten kontinuierlich oder bei Bedarf bereitstellen. Weiterhin ist die Unterscheidung in Betriebsweise mit fester Abtastfrequenz f_A und die Betriebsweise mit veränderlichen, im *nicht-deterministischen Falle* unbekannten Abtastzeitpunkten t_a möglich. Die Bereitstellung von Daten im Bedarfsfall entspricht dem asynchronen Modus. Bei kontinuierlicher Bereitstellung von Messwerten ist die synchrone Betriebsweise häufig anzutreffen; prinzipiell sind aber beide Modi möglich. Die Abtastfrequenz f_A bestimmt bei der kontinuierlichen, synchronen Abtastung das Intervall zwischen zwei Messungen. Jeder Sensor benötigt zudem ein bestimmtes Zeitintervall zur Abtastung der Messgröße.

Zeitabhängige Datenaktualisierung Bei der Bereitstellung von Daten im Bedarfsfall entscheidet das Alter der bereits vorhandenen Daten über die Notwendigkeit einer neuen Messung. Im Falle einer kontinuierlichen Bereitstellung von Messdaten durch die Sensorik wählen nachgeschaltete Signalverarbeitungsstufen bei Bedarf das entsprechende Messdatum.

Zeitcharakteristik der Signalverarbeitungsmodule Ebenso wie Sensoren verarbeiten die einzelnen Signalverarbeitungsmodule die Daten innerhalb eines bestimmten Zeitintervalls. Bei hintereinandergeschalteten Modulen addieren sich diese Einzelintervalle. Signalverarbeitungsstufen am Ende der Signalverarbeitungskette – Regelalgorithmen oder Entscheidungsstufen – müssen den Bezug des aktuellen Zeitpunktes zum Abtastzeitpunkt berücksichtigen. Im Falle des Versuchssystems ergeben sich so die für die Ermittlung der Abtastzeitpunkte bzw. die Zuordnung der Daten der verschiedenen Sensoren innerhalb des Echtzeitrechners zu betrachtenden Zeitspannen

$$\begin{aligned}\Delta T_{m_{\text{Radar1,2}}} &= T_{SP_{\text{start}}} - T_{m(\text{Radar1,2})} \\ &= \Delta t_{\text{INIT}(\text{Radar1,2})} + \Delta t_{\text{Radar1,2}} + \\ &\quad + \Delta t_{\text{Clock}(\text{Radar1,2})} + \\ &\quad + \Delta t_{\text{Request}} + \Delta t_{\text{Readout}}\end{aligned}\tag{5.1}$$

$$\begin{aligned}\Delta T_{m_{\text{LMS}}} &= T_{SP_{\text{start}}} - T_{m(\text{LMS})} \\ &= \Delta t_{\text{INIT}(\text{LMS})} + \Delta t_{\text{LMS}} + \\ &\quad + \Delta t_{\text{Clock}(\text{LMS})}\end{aligned}\tag{5.2}$$

mit

$$\Delta T_{\text{Radar1,2}} \neq \Delta T_{\text{LMS}}\tag{5.3}$$

$$\Delta T_{\text{Radar1,2}} \leq T; \Delta T_{\text{LMS}} \leq T.\tag{5.4}$$

In Anlehnung an Abbildung 5.1 sind $T_{SP_{\text{start}}}$ Startzeitpunkt der Signalverarbeitung, $T_{m(\text{Radar1,2})}$ der Zeitpunkt der im Signalverarbeitungsmodul (CPU-Board2) vorliegenden Messung eines

Radarsensoren, $\Delta t_{INIT(Radar1,2)}$ die benötigte Laufzeit für den Startbefehl, $\Delta t_{Radar1,2}$ die Zeitspanne für die Abtastung, $\Delta t_{Clock(Radar1,2)}$ die Taktverschiebung, $\Delta t_{Request}$ die Laufzeit für die Anforderung zum Senden eines Messwertes und $\Delta t_{Readout}$ die Zeit bis zur Ankunft der Messdaten. Für den Laserscanner reduzieren sich die Einflussfaktoren aufgrund der direkten Anbindung an den Signalverarbeitungsrechner auf die benötigte Laufzeit für den Startbefehl $\Delta t_{INIT(LMS)}$, die Zeitspanne für die Abtastung und Bereitstellung der Daten Δt_{LMS} und die Taktverschiebung $\Delta t_{Clock(LMS)}$. Die Summe aller Zeitspannen muss kleiner als die Zykluszeit T des Signalverarbeitungssystems sein. Die Festlegung der Aktivierungszeit T_a für nachgeschaltete Einrichtungen muss unter Beachtung von

$$\begin{aligned} \Delta T_{m/a} &= T_a - T_m \\ &= \Delta t_{INIT} + \Delta t_{Sensor} + \Delta t_{Clock(Sensor)} + \Delta t_{SP} \\ &\quad [+ \Delta t_{Request} + \Delta t_{Readout}] \\ &\leq 2 \cdot T \end{aligned} \tag{5.5}$$

erfolgen. Das bedeutet, dass die Aktivierung von nachgeschalteten Systemen bei kontinuierlicher Arbeitsweise des Signalverarbeitungssystems und aufgrund oft unbekannter Zeitspannen bzw. Abtastzeitpunkte um $2 \cdot T$ vorzuverlegen ist, um in allen Fällen eine rechtzeitige Auslösung garantieren zu können.

Dynamik der Szene Die Zeitangaben in Verbindung mit den Sensordaten (Positionsdaten) dienen zur Berechnung der Parameter von Objekten einer Szene. Die mögliche Dynamik von Szenen hat Einfluss auf die Wahl der Sensorik, speziell in Hinsicht auf die zur Bereitstellung benötigte Zeit und die Abtastfrequenz f_A .

Auswirkung der Zeitcharakteristik der Sensoren und Lösungsansätze

Multisensorsysteme zur Umfelderkennung verwenden Daten verschiedener Sensoren, um eine verbesserte Beschreibung des Umfelds bzw. eines beobachteten Objekts zu erhalten. Sie fassen die Beobachtungen mehrerer Sensoren zu einer globalen Beobachtung zusammen. Gerade bei der Verknüpfung der Daten mehrerer Sensoren führen unterschiedliche Zeitcharakteristiken zu Schwierigkeiten und der Notwendigkeit, die Daten aus den unterschiedlichen Quellen zu synchronisieren. Sie bestimmen damit entscheidend den Aufbau der verwendeten Fusionsarchitektur.

Die Synchronisierung der Sensordaten innerhalb einer Fusionsarchitektur kann sowohl durch die zeitliche Synchronisation der Sensoren selbst als auch durch die Synchronisation der Daten, zum Beispiel mittels Tracking-Algorithmus erfolgen. Eine Möglichkeit ist dabei die in [BP99] beschriebene Methode, die Daten entsprechend ihrer zeitlichen Ankunft im Tracking-Filter zu verarbeiten. Das Filter prädiziert dabei einen neuen Systemzustand für den jeweiligen Messzeitpunkt und verknüpft die zu diesem Zeitpunkt entstandene Prädiktion mit der Messung zu einer neuen Schätzung. Ein Problem dieser Methode stellt jedoch der hohe Rechenzeitaufwand dar. In Fällen, in denen das Fusionssystem die Daten unterschiedlicher Sensoren nicht zeitlich getrennt verknüpfen kann (kooperative Fusion, Rechenzeitprobleme etc.), ist der Fusionsschritt zeitlich einem Sensor oder einem internen Zeitraster zuzordnen. Dies hat dann den Nachteil, dass Daten anderer Sensoren unter Umständen bereits veraltet sind, Zuordnungsprobleme entstehen können oder Latenzzeiten verlängert werden.

In [NK03] sind die Zusammenhänge und Wirkungen unterschiedlicher Zeitcharakteristiken von Sensoren ausführlicher beschrieben.

5.2 Bekannte Verfahren zur Fusion der Sensordaten

Im vorgestellten System sind Sensoren miteinander zu fusionieren, die ähnliche Daten in Form von Positionsangaben liefern. Für die (konkurrierende) Fusion solcher Daten existiert bereits eine Vielzahl von Ansätzen. Die Verknüpfung der Sensordaten geschieht dabei zumeist innerhalb der Tracking-Stufe.

Der folgende Abschnitt stellt einige bekannte Ansätze zur Fusion von Sensordaten innerhalb von Central Level- und Sensor Level-Fusionsarchitekturen kurz vor. Die aufgeführten Verfahren stellen allerdings nur eine Auswahl dar, die besonders für den gegebenen Einsatzzweck in Frage kommen.

5.2.1 Messwerte-Fusion

Ansätze zur Fusion der Messwerte sind typisch für Central-Level-Fusionsarchitekturen. Jeder Sensor sendet seine unbearbeiteten oder nur minimal vorverarbeiteten Daten an ein Fusionsmodul, welches die Daten kombiniert und weiterverarbeitet. Der Kern des Fusionsmoduls besteht in aller Regel aus einem Kalman-Filter. Die Durchführung kann mittels drei im Folgenden beschriebenen, mathematisch äquivalenten Verfahren erfolgen [BP99, WCD76].

Messvektor-Fusion

Bei der Messvektor-Fusion steht die Bildung eines kombinierten Messvektors $\mathbf{z}_{k,c}$ aus den Messvektoren $\mathbf{z}_{k,i}$ der einzelnen Datenquellen an erster Stelle. Das Fusionsmodul verarbeitet dann diesen kombinierten Messwert wie den Messwert eines einzelnen Sensors innerhalb eines Kalman-Filters. Die Verknüpfung der Daten der unterschiedlichen Sensoren erfolgt gewichtet. Die Gewichte resultieren aus den bekannten Messungenauigkeiten, die in den jeweiligen Messfehlerkovarianzmatrizen \mathbf{R}_i abgelegt sind:

$$\mathbf{z}_{k,c} = \frac{\mathbf{R}_2}{\mathbf{R}_1 + \mathbf{R}_2} \cdot \mathbf{z}_{k,1} + \frac{\mathbf{R}_1}{\mathbf{R}_1 + \mathbf{R}_2} \cdot \mathbf{z}_{k,2}. \quad (5.6)$$

Die kombinierte Messfehlerkovarianzmatrix \mathbf{R}_c ergibt sich dann aus:

$$\mathbf{R}_c = \frac{\mathbf{R}_1 \mathbf{R}_2}{\mathbf{R}_1 + \mathbf{R}_2}. \quad (5.7)$$

Das Verfahren ist sehr einfach, kann aber nur bei gleichartigen Messvektoren zur Anwendung kommen.

Kalman-Filter mit mehreren Eingängen

Ein weiterer Ansatz besteht in der Verwendung eines Kalman-Filters mit mehreren Eingängen [Bec02]. Hierbei geschehen sowohl die Prädiktion eines neuen Zustandes

$$\hat{\mathbf{s}}_k^- = \mathbf{A} \hat{\mathbf{s}}_{k-1} \quad (5.8)$$

mit Hilfe der Zustandsübergangsmatrix \mathbf{A} als auch die Berechnung der erwarteten Fehler der Prädiktion in Form einer Kovarianzmatrix unter Einbeziehung des in \mathbf{Q} abgelegten Modellfehlers

$$\mathbf{P}_k^- = \mathbf{A}\mathbf{P}_{k-1}\mathbf{A}^T + \mathbf{Q} \quad (5.9)$$

analog der Vorgehensweise bei Benutzung eines Kalman-Filters mit nur einem Eingang (vgl. Abschnitt 4.3.2 auf Seite 76). Die neue Schätzung $\hat{\mathbf{s}}_k$ ist nun aus den jeweiligen Messmatrizen \mathbf{C}_i , Kalman-Gains $\mathbf{K}_{k,i}$ und Messvektoren $\mathbf{z}_{k,i}$ für jeden Sensor i zu berechnen:

$$\hat{\mathbf{s}}_k = \hat{\mathbf{s}}_k^- + \mathbf{K}_{k,1} \cdot (\mathbf{z}_{k,1} - \mathbf{C}_1 \cdot \hat{\mathbf{s}}_k^-) + \mathbf{K}_{k,2} \cdot (\mathbf{z}_{k,2} - \mathbf{C}_2 \cdot \hat{\mathbf{s}}_k^-). \quad (5.10)$$

Für zwei Sensoren erfolgt die Berechnung der \mathbf{K}_i entsprechend [Bec02]:

$$\mathbf{K}_{k,1} = \mathbf{P}_k^- \left(\frac{\frac{\mathbf{C}_2^T}{\mathbf{C}_2\mathbf{P}_k^-\mathbf{C}_2^T + \mathbf{R}_2} - \frac{\mathbf{C}_1^T}{\mathbf{C}_2\mathbf{P}_k^-\mathbf{C}_1^T}}{\frac{\mathbf{C}_1\mathbf{P}_k^-\mathbf{C}_2^T}{\mathbf{C}_2\mathbf{P}_k^-\mathbf{C}_2^T + \mathbf{R}_2} - \frac{\mathbf{C}_1\mathbf{P}_k^-\mathbf{C}_1^T + \mathbf{R}_1}{\mathbf{C}_2\mathbf{P}_k^-\mathbf{C}_1^T}} \right) \quad (5.11)$$

$$\mathbf{K}_{k,2} = \mathbf{P}_k^- \left(\frac{\frac{\mathbf{C}_1^T}{\mathbf{C}_1\mathbf{P}_k^-\mathbf{C}_1^T + \mathbf{R}_1} - \frac{\mathbf{C}_2^T}{\mathbf{C}_1\mathbf{P}_k^-\mathbf{C}_2^T}}{\frac{\mathbf{C}_2\mathbf{P}_k^-\mathbf{C}_1^T}{\mathbf{C}_1\mathbf{P}_k^-\mathbf{C}_1^T + \mathbf{R}_1} - \frac{\mathbf{C}_2\mathbf{P}_k^-\mathbf{C}_2^T + \mathbf{R}_2}{\mathbf{C}_1\mathbf{P}_k^-\mathbf{C}_2^T}} \right). \quad (5.12)$$

Die resultierende Fehlerkovarianzmatrix \mathbf{P}_k ergibt sich dann aus:

$$\begin{aligned} \mathbf{P}_k &= (\mathbf{I} - \mathbf{K}_{k,1}\mathbf{C}_1 - \mathbf{K}_{k,2}\mathbf{C}_2)\mathbf{P}_k^-(\mathbf{I} - \mathbf{K}_{k,1}\mathbf{C}_1 - \mathbf{K}_{k,2}\mathbf{C}_2)^T \\ &\quad + \mathbf{K}_{k,1}\mathbf{R}_1\mathbf{K}_{k,1}^T + \mathbf{K}_{k,2}\mathbf{R}_2\mathbf{K}_{k,2}^T. \end{aligned} \quad (5.13)$$

Bei identischen Messmatrizen ist eine Vereinfachung der Formeln möglich. Nachteilig an diesem Verfahren ist der erhöhte Rechenaufwand, was unter Umständen einen Einsatz bei der Fusion einer großen Anzahl von Sensoren unmöglich macht.

Sequentielle Verarbeitung mittels Kalman-Filter

Diese Form der Messdatenfusion ist besonders für die Verknüpfung von Daten asynchroner Sensoren geeignet. Das Tracking-Filter prädiziert den neuen Systemzustand für den Zeitpunkt jedes eintreffenden Messwertes und verknüpft dann den jeweiligen Messwert mit dieser Schätzung. Bei der Verwendung synchroner Sensoren und Abarbeitung dieser Sensoren entsprechend ihrer Genauigkeit verkleinern sich die Suchbereiche des Assoziationsschrittes, was die Leistung des Assoziationsschrittes verbessern kann [BP99]. Ein Nachteil dieses Verfahrens ist jedoch der erhöhte Rechenaufwand, der durch die für jeden Sensor durchgeführten Filterdurchläufe entsteht.

5.2.2 Track-to-Track-Fusion

Innerhalb einer Sensor-Level-Fusionsarchitektur ist das Verknüpfen zweier Tracks eine übliche Vorgehensweise. Die hierfür verwendeten Eingangsdaten entstehen innerhalb vorgelagerter und für jeden Sensor getrennter Signalverarbeitungsstufen. Im Folgenden sind zwei Vertreter von Track-to-Track-Fusionsverfahren beschrieben.

Simple Fusion

Ein erster, von R. A. Singer und A. J. Kanyuck entwickelter Track-to-Track-Fusionsalgorithmus ist die *Simple Fusion* [SK71]. Sensorspezifische Tracking-Filter (Kalman-Filter) verarbeiten die Sensordaten und liefern Schätzungen $\hat{\mathbf{s}}_{k,i}$ und die zugehörigen Schätzfehlerkovarianzmatrizen $\mathbf{P}_{k,i}$. Ein Fusionsmodul erzeugt daraus mittels

$$\hat{\mathbf{s}}_k = \frac{\mathbf{P}_{k,2}}{\mathbf{P}_{k,1} + \mathbf{P}_{k,2}} \cdot \hat{\mathbf{s}}_{k,1} + \frac{\mathbf{P}_{k,1}}{\mathbf{P}_{k,1} + \mathbf{P}_{k,2}} \cdot \hat{\mathbf{s}}_{k,2} \quad (5.14)$$

die globale Schätzung $\hat{\mathbf{s}}_k$. Die kombinierte Schätzfehlerkovarianzmatrix berechnet sich aus:

$$\mathbf{P}_k = \frac{\mathbf{P}_{k,1} \cdot \mathbf{P}_{k,2}}{\mathbf{P}_{k,1} + \mathbf{P}_{k,2}}. \quad (5.15)$$

Das Verfahren basiert auf der Annahme unkorrelierter sensorspezifischer (lokaler) Tracks, um den Voraussetzungen für den Einsatz eines globalen Kalman-Filters zu genügen. Dies ist jedoch nicht der Fall, da beide Tracks über ein gemeinsames Prozessrauschen verfügen. Die Qualität der Ergebnisse dieses Algorithmus sind damit gut, aber nicht optimal [BSLS00]. Ein weiterer Nachteil ist der erhöhte Rechenaufwand bei parallelen Tracking-Filtern und der potentiell größere Verlust an Information gegenüber Central-Level-Architekturen, der durch die getrennte Verarbeitung der Sensordaten entstehen kann.

Weighted Covariance Fusion

Ein weiterer Vertreter von Track-to-Track-Fusionsverfahren, die *Weighted Covariance Fusion* [BS81, BSC86], berücksichtigt die Korrelation zwischen den lokalen Tracks durch eine Kreuzkovarianzmatrix. Die Bildungsvorschrift für die globale Schätzung lautet

$$\hat{\mathbf{s}}_k = \hat{\mathbf{s}}_{k,1} + \mathbf{W}_k \cdot (\hat{\mathbf{s}}_{k,2} - \hat{\mathbf{s}}_{k,1}), \quad (5.16)$$

mit der Gewichtungsmatrix \mathbf{W}_k , die ähnlich dem Kalman-Gain ist. Diese Gewichtungsmatrix wiederum ergibt sich aus

$$\mathbf{W}_k = (\mathbf{P}_{k,1} - \mathbf{P}_C) \cdot \mathbf{P}_E^{-1} \quad (5.17)$$

mit

$$\mathbf{P}_C = E[\tilde{\mathbf{s}}_1 \tilde{\mathbf{s}}_2^T], \quad (5.18)$$

der Kreuzkovarianzmatrix \mathbf{P}_C und den Prädiktionsfehlern $\tilde{\mathbf{s}}_{k,i}$ der jeweiligen Kalman-Filter i und

$$\mathbf{P}_E = (\mathbf{P}_{k,1} + \mathbf{P}_{k,2}) - (\mathbf{P}_C + \mathbf{P}_C^T). \quad (5.19)$$

Die Berechnung der resultierenden Fehlerkovarianzmatrix \mathbf{P}_k erfolgt mittels

$$\mathbf{P}_k = \mathbf{P}_{k,1} - (\mathbf{P}_{k,1} - \mathbf{P}_C) \mathbf{P}_E^{-1} (\mathbf{P}_{k,1} - \mathbf{P}_C)^T. \quad (5.20)$$

Die Verwendung einer Kreuzkovarianzmatrix bringt nur dann Vorteile, wenn sie positiv definit ist [Sah96]. Ansonsten verringert sich die Qualität der Schätzungen und ist dann teilweise

schlechter als die der Simple Fusion. Die Weighted Covariance Fusion ist zwar optimal im Sinne einer Maximum Likelihood-Schätzung, aber suboptimal im Sinne einer Minimierung der Summe der Fehlerquadrate [CSBS97, CTS98].

Die Nachteile des erhöhten Rechenaufwandes durch parallele Verarbeitung der Sensordaten und des potentiell größeren Verlustes an Information gegenüber Central-Level-Architekturen durch „späte“ Fusion hat dieses Verfahren mit der Simple Fusion gemein.

5.3 Implementierte Verfahren

Ziel der Fusion von Laserscanner und Nahbereichsradares, ist, wie bereits in Kapitel 3.2 beschrieben, der Aufbau eines zuverlässigen PreCrash-Systems. Die Anforderungen im Automobilbereich an die Kosten solcher Systeme macht die Implementierung effizienter und wenig rechenzeit- und speicherintensiver Algorithmen notwendig.

Der folgende Abschnitt beschreibt zwei Fusionsansätze im Detail, die letztendlich für das PreCrash-System zur Anwendung kamen. Das am Anfang beschriebene Verfahren entspricht einer bereits bekannten Vorgehensweise. Ein zweites Verfahren, speziell für die Fusion von Laserscanner und Radar entwickelt, wird im zweiten Teil vorgestellt. In beiden Abschnitten sind sowohl offensichtliche Vorteile als auch die Nachteile der Verfahren zusammengestellt.

5.3.1 Messvektor-Fusion

Ein erstes implementiertes Verfahren ist die Fusion der Messwerte. Gegenüber Track-to-Track-Fusionsansätzen bietet es den Vorteil einer „zeitigeren“ Fusion und der damit verbundenen potentiell besseren Ausnutzbarkeit der Sensordaten bzw. der Detektionsleistungen der Sensorik. Aufgrund der Tatsache, dass alle drei im Abschnitt 5.2.1 beschriebenen Verfahren mathematisch äquivalent sind [BP99] und die Abtastzeitpunkte der Sensoren im Versuchssystem aufgrund unbekannter Zeitspannen (Gleichungen 5.1 und 5.2) nicht exakt bestimmbar sind, fiel die Wahl auf die *Messvektor-Fusion* als einfachstes Verfahren, welches zudem die geringsten Anforderungen an die Rechenzeit stellt.

Die Trackingstufe stellt damit das Fusionsmodul dar, die eigentliche Verknüpfung der Daten findet am Eingang dieses Moduls statt (Abbildungen 5.2 und 5.3). Grundlage dieses Tracking-Filters ist das in den Kapiteln 4.3.2 und 4.3.3 beschriebene Verfahren inklusive der dort aufgeführten Erweiterungen wie zum Beispiel adaptive Prozessfehler- und Messkovarianzmatrizen.

Die Fusion der Messwerte bzw. der jeweiligen Anteile e des Messvektors des Laserscanners $z_{e,LMS}$ und der Nahbereichsradares $z_{e,R1}$, $z_{e,R2}$ erfolgt unter Einbeziehung der jeweiligen Varianzen entsprechend Gleichung 5.6:

$$z_{e,c} = \frac{\frac{z_{e,LMS}}{\sigma_{e,LMS}} + \frac{z_{e,R1}}{\sigma_{e,R1}} + \frac{z_{e,R2}}{\sigma_{e,R2}}}{\frac{1}{\sigma_{e,LMS}} + \frac{1}{\sigma_{e,R1}} + \frac{1}{\sigma_{e,R2}}}. \quad (5.21)$$

Die Varianz der kombinierten Messwerte ergibt sich dann entsprechend Gleichung 5.7:

$$\frac{1}{\sigma_{e,c}} = \frac{1}{\sigma_{e,LMS}} + \frac{1}{\sigma_{e,R1}} + \frac{1}{\sigma_{e,R2}}. \quad (5.22)$$




Abbildung 5.2: Fusion innerhalb der Tracking-Stufe

Voraussetzung für die Anwendung beider Verknüpfungsvorschriften ist, dass nur die Hauptdiagonalen der Fehlerkovarianzmatrizen für Laserscanner

$$\mathbf{R}_{LMS} = \begin{pmatrix} \sigma_{LMS,x}^2 & 0 & 0 \\ 0 & \sigma_{LMS,y}^2 & 0 \\ 0 & 0 & \sigma_{LMS,\beta}^2 \end{pmatrix} \quad (5.23)$$

und die zwei Nahbereichsradare

$$\mathbf{R}_{R1} = \mathbf{R}_{R2} = \begin{pmatrix} \sigma_{R,x}^2 & 0 & 0 \\ 0 & \sigma_{R,y}^2 & 0 \end{pmatrix} \quad (5.24)$$

besetzt sind¹. Zu beachten sind ebenfalls die unterschiedlichen Dimensionen der Kovarianzmatrizen und der Messvektoren. Die Radare liefern keinen Beitrag zur Schätzung des Orientierungswinkels beobachteter Objekte. Da die Genauigkeit der Winkelangaben der Nahbereichsradare mit steigendem Winkel abnimmt und die gelieferten Daten aller Sensoren in Form von Abstand und Winkel in das kartesische Koordinatensystem transformiert werden, muss die Festlegung der Werte für \mathbf{R}_{LMS} , \mathbf{R}_{R1} und \mathbf{R}_{R2} adaptiv, d. h. entsprechend der Lage der Messpunkte erfolgen.

Im Gegensatz zum Tracking-Filter für einen Einzelsensor wie zum Beispiel den Laserscanner ergeben sich bei der Fusion vor allem im Assoziationsschritt Unterschiede. So sind bei der Berechnung des Suchbereiches

$$D^2 = \frac{(x_P - x_M)^2}{\sigma_x^2} + \frac{(y_P - y_M)^2}{\sigma_y^2} \leq 1 \quad (5.25)$$

neben den Prädiktionsfehlern $\sigma_{x,P}^2$ und $\sigma_{y,P}^2$ aus der Prädiktionskovarianzmatrix und den Messfehlern $\sigma_{x,M}^2$ und $\sigma_{y,M}^2$ auch durch unterschiedliche Messzeitpunkte bzw. ungenügende

¹Aufgrund der Messverfahren und der gelieferten Daten in Form von Winkel und Abstand sind die Fehler in x und y natürlich nicht unabhängig voneinander. Dies stellt eine Vereinfachung dar, die aber bei ohnehin adaptiver Festlegung der Werte zulässig ist.

Synchronisation hervorgerufene Fehler $\sigma_{x,S}^2$ bzw. $\sigma_{y,S}^2$ zu berücksichtigen:

$$\sigma_x^2 = \sigma_{x,P}^2 + \sigma_{x,M}^2 + \sigma_{x,S}^2 \quad (5.26)$$

$$\sigma_y^2 = \sigma_{y,P}^2 + \sigma_{y,M}^2 + \sigma_{y,S}^2. \quad (5.27)$$

Diese Synchronisationsfehler sind im vorliegenden System, dessen Sensoren gleiche, feste Abtastfrequenzen besitzen, die aber zu unbekannten Zeiten messen, auch von der Objektgeschwindigkeit und der Abtastfrequenz abhängig (vgl. 3σ -Methode in Abschnitt 4.3.2):

$$\sigma_{x,S}^2 = \left(\frac{1}{3}v_x \cdot T\right)^2 \quad (5.28)$$

$$\sigma_{y,S}^2 = \left(\frac{1}{3}v_y \cdot T\right)^2. \quad (5.29)$$

Es können bei der Zuordnung Fälle auftreten, bei denen die Radarsensoren Punkte liefern,




Abbildung 5.3: Struktur des Fusionsmoduls (Messvektorfusion)

die außerhalb des Gates, aber innerhalb der Objektbox liegen. Auch diese ordnet der Assoziationsschritt dem Objekt zu. Diese Ziele gehen jedoch nicht in die Positionsschätzung des Objekts mit ein, da das Reflexionszentrum offensichtlich weit vom Objektreferenzpunkt entfernt war.

Die Zuordnung von Laserscanner-Messwerten in Form von Segmenten geschieht nach dem in Abschnitt 4.3.2 beschriebenen *Global Nearest Neighbor*-Verfahren. Im Unterschied dazu ordnet der Assoziationsschritt jedoch alle Daten der Nahbereichsradare Objekten zu, die innerhalb des Suchbereiches oder der Objektbox liegen, da die Radare durchaus mehrere Messwerte

pro Objekt liefern können. Die Lösung von Konfliktfällen (mehrere Objekte „beanspruchen“ dieselben Messwerte) geschieht wie beim Einzelsensorsystem durch die Einbeziehung von Objektzuständen. Bei gleichen Objektzuständen und Konflikten bezüglich Radardaten „gewinnt“ das Objekt, welchem bereits Laserscanner-Daten zugeordnet wurden bzw. das Objekt zu dessen Prädiktion die kürzeste statistische Distanz besteht. Weitere Konfliktlösungsansätze sind bei Konfliktfällen mit Radar-Messungen nicht möglich, da die Aussagekraft der mitgelieferten Geschwindigkeiten und Amplituden für eine sichere Entscheidung zu gering ist.

Bei genaueren Informationen bezüglich der realen Messzeitpunkte bietet sich statt der Messvektor-Fusion der Ansatz der sequentiellen Abarbeitung der eingehenden Daten mittels Tracking-Filter an. Die notwendigen Änderungen gegenüber dem beschriebenen Verfahren sind dann nur sehr gering: Anstelle der gleichzeitigen Fusion der Messdaten aller Sensoren am Filtereingang verarbeitet das Filter dann die Daten für jeden (Sensor-)Messzeitpunkt einzeln.

Problematisch bei Einsatz der Messwerte-Fusion ist aber die Verknüpfung von Daten, deren Referenzpunkte auf unterschiedliche Weise zustandekommen. So ist die genaue Lage des Reflexionszentrums für Radarsignale an Objekten im Umfeld des Fahrzeuges unbekannt. Damit ist auch der Lagebezug zwischen beiden Referenzpunkten unbekannt. Eine Verknüpfung beider Referenzpunkte erzeugt damit Fehler. Eine Entwicklung von Modellen bezüglich des Reflexionszentrums bei Radarmessungen ist aufgrund der Vielzahl an Objektklassen und deren Variationen sehr schwierig. Ein einfaches Modell besteht in der Annahme, dass die Reflexionszentren auf dem zu dem jeweiligen Sensor naheliegendsten Punkt des Objekts $\mathbf{z}_{N,LMS}^{x,y}$ liegen:

$$\mathbf{d}_m = \mathbf{z}_{LMS}^{x,y} - \mathbf{z}_{N,LMS}^{x,y} \quad (5.30)$$

$$\mathbf{z}_{R1}^- = \mathbf{z}_{R1} + \mathbf{d}_m \quad (5.31)$$

$$\mathbf{z}_{R2}^- = \mathbf{z}_{R2} + \mathbf{d}_m \quad (5.32)$$

und nur die korrigierten Messwerte \mathbf{z}_{R1}^- sowie \mathbf{z}_{R2}^- mit den Laserscanner-Messwerten fusioniert werden. Eine besonders geringe Berücksichtigung der durch die Radare gelieferten Positionsinformationen in Fällen, in denen Laserscanner-Daten vorhanden sind, kann ebenfalls (teilweise) Abhilfe schaffen.

Ein weiterer Nachteil dieses Fusionsansatzes besteht in der Tatsache, dass die Verknüpfung der Daten verschiedener Sensoren erst nach Vorverarbeitungsschritten erfolgt, was die optimale Ausnutzung der Detektionsleistung kombinierter Sensoren erschwert.

Die Anforderungen an die Rechenleistungen sind während des eigentlichen Fusionsvorganges zwar sehr gering, der Aufwand im Assoziationsschritt wächst aber mit der Anzahl der Sensoren. Die dort ansteigende Komplexität erhöht die Gefahr bzw. potentiell die Anzahl von Fehlern während der Implementierung.

5.3.2 Fusion mittels Segmentierungsgitter

Ein während der Arbeiten speziell für die Fusion von Laserscanner und Nahbereichsradar entwickeltes Verfahren findet als zweite Variante Anwendung. Hier stellt die Segmentierungsstufe das Fusionsmodul dar (Abbildungen 5.4 und 5.5). Die Segmentierungsstufe bezieht neben den Messwerten des Laserscanners auch die durch Punkte repräsentierten Radardaten




Abbildung 5.4: Fusion innerhalb der Segmentierungsstufe

in die Segmentierung ein [Uzu05a]. Das Modul projiziert analog der in Kapitel 4.2.1 beschriebenen Vorgehensweise alle Daten in ein Gitter und markiert alle Zellen, die mit einer bestimmten Mindestanzahl von Messwerten belegt sind. Ein Cluster-Verfahren (Connected-Component-Labeling) verbindet alle benachbarten Zellen. Die so gewonnene Information über zusammengehörende Messpunkte geht nun in die Beschreibung der Segmente ein. Alle nachfolgenden Schritte entsprechen denen eines ausschließlich auf Laserscanner basierenden Umfelderkennungssystems: Merkmale wie Referenzpunkt, Orientierungswinkel und Seitenlängen der extrahierten Segmente stellen die Eingangswerte für ein Tracking-Filter dar. Dieses Filter entspricht dem in Abschnitt 4.3 beschriebenen Verfahren. Die Bildung der Messkovarianzmatrix \mathbf{R} erfolgt entsprechend den mengenmäßigen Anteilen n_X des jeweiligen Sensors an den Messpunkten, die ein Segment bilden:

$$\mathbf{R} = \frac{n_{LMS}}{n_{LMS} + n_{R1} + n_{R2}} \cdot \mathbf{R}_{LMS} + \frac{n_{R1}}{n_{LMS} + n_{R1} + n_{R2}} \cdot \mathbf{R}_{R1} + \frac{n_{R2}}{n_{LMS} + n_{R1} + n_{R2}} \cdot \mathbf{R}_{R2}. \quad (5.33)$$

Die Berücksichtigung der größeren Ungenauigkeit der Radardaten erfolgt durch Hinzufügen zusätzlich generierter Messpunkte (Hilfspunkte) entsprechend der jeweiligen Varianzwerte, adaptiv in Abhängigkeit von der Lage des Messpunktes. Diese zusätzlichen Messpunkte dienen jedoch nur der Anpassung der Genauigkeit der Radarsensoren an das Gitter während des Zusammenfassens von Punkten; bei der Bildung des Segments und seiner Merkmale finden sie keine Berücksichtigung. Eine Alternative hierzu wäre die Zuordnung der Radarpunkte zu den Laserscanner-Messungen unter Verwendung eines weiteren, speziell an die Eigenschaften der Radare angepassten Gitters.

Die Verknüpfung der Daten findet damit schon sehr zeitig statt, was zumindest potentiell eine bessere Ausnutzung der Detektionsleistung aller Sensoren ermöglicht. Auch erhöht sich die Komplexität des Systems durch Hinzufügen zusätzlicher Sensorik nur unwesentlich. So entspricht beispielsweise die Assoziationsstufe des Tracking-Filters der eines Einzelsensorsystems.




Abbildung 5.5: Struktur des Fusionsmoduls (Fusion innerhalb der Segmentierungsstufe)

Die Problematik der unterschiedlichen Referenzpunkte bei unterschiedlichen Messverfahren kommt hier weniger zur Geltung, da sich die Radar-Messwerte in die Kontur des Objektes einfügen und nicht als Referenzpunkte behandelt werden.

Ein Nachteil dieses Verfahrens ist jedoch die fehlende Berücksichtigung des durch ungenügende Synchronisation der verschiedenen Sensoren auftretenden Fehlers. Zusätzlich können Probleme bei der Einbeziehung ungenauer Radarmessungen in Form fälschlicher Zusammenfassungen nicht zueinander gehörender Messpunkte auftreten.

6 Umfeldbeschreibung und Entscheidungsalgorithmen

Mit den von der Sensorik und den vorgelagerten Signalverarbeitungsstufen gelieferten und möglichst kompletten Informationen bezüglich der Fahrzeugumgebung ist es Aufgabe der Umfeldbeschreibung und eines Entscheidungs-Algorithmus, Situationen zu beschreiben, zu bewerten und entsprechende Aktionen auszulösen. Erste Schritte sind dabei das Extrahieren relevanter Daten und die Vorhersage zukünftiger Objektpositionen bzw. -bewegungen. Derartige Verarbeitungsschritte finden in der Umfeldbeschreibungs-/Vorhersage-Stufe statt (Abbildung 6.1). Ein weiterer Schritt ist die Einordnung der extrahierten Informationen bezüglich ihrer Relevanz für die vorgegebene Anwendung. Das schließt im Falle eines PreCrash-Systems




Abbildung 6.1: Entscheidungsstufe im Multisensorsystem

die Frage ein, ob das eigene Fahrzeug mit einem Objekt zusammenstoßen wird oder nicht. Eine Entscheidungsstufe bewertet dafür die Qualität der bereitgestellten Informationen, fällt die endgültige Entscheidung und leitet gegebenenfalls entsprechende Informationen an eine Aktuatorik weiter. An dieser Stelle findet je nach Anzahl verwendeter Sensoren ebenfalls eine Fusion von Informationen statt, um die Zuverlässigkeit der Entscheidungsstufe zu erhöhen. Die Umfeldbeschreibung ist sehr stark mit den Entscheidungsalgorithmen verbunden. Sie liefert die für einen Entscheidungsalgorithmus nötigen Informationen und stellt somit ein Filter dar, der abhängig von der Applikation arbeitet. Aufgrund der einerseits logischen Trennung zwischen Umfeldbeschreibung und Entscheidungsstufe, aber andererseits direktem funktionellen Zusammenhang sind in diesem Kapitel mögliche Ansätze für beide Module gemeinsam beschrieben.

6.1 Umfeldbeschreibung und Vorhersage

Die Beschreibung des Umfelds und die Vorhersage von zukünftigen Objektzuständen schließt sich direkt an die Tracking-Stufe an. Das Signalverarbeitungsmodul speichert hierfür Informationen aus der Vergangenheit, berechnet zu jedem aktuellen Zeitpunkt k zukünftige Objektzustände und trifft bereits eine Vorauswahl potentiell gefährlicher Objekte.

Das Speichern von Objektdaten geschieht jeweils für mehrere Zyklen F . Diese Daten stehen dann später zur Glättung oder zur Prädiktion von Werten wie zum Beispiel Geschwindigkeit oder Position zur Verfügung. Die Länge des Zeitfensters F bestimmt dabei entscheidend die Qualität der getroffenen Aussagen: Zu kurze Zeitfenster filtern Störungen bzw. Rauschen nur sehr ungenügend, während zu lange Zeitfenster eine zu träge Reaktion auf Änderungen bewirken. Die durch das System gespeicherten Objektdaten sind in Tabelle 6.1 dargestellt,

Merkmal	Beschreibung
<i>state</i>	Objektzustand
<i>center</i>	Objektmittelpunkt (Objektbox)
<i>cog</i>	Objektschwerpunkt (Center of Gravity)
<i>nearest</i>	Nächster Punkt zum Laserscanner
<i>min_ang</i>	Punkt mit dem kleinsten Winkel
<i>max_ang</i>	Punkt mit dem größten Winkel
<i>crossline</i>	Objekt verschwindet aus Sichtfeld (Flag)
v_x	Geschwindigkeit in x-Richtung
v_y	Geschwindigkeit in y-Richtung
<i>angle</i>	Orientierungswinkel der Objektbox
dim_x	Länge der Objektbox
dim_y	Breite der Objektbox
<i>no_points</i>	Anzahl der Laserscannermesspunkte
<i>sensor_observed</i>	Welche Sensoren detektieren das Objekt?
berechnetes Merkmal	Beschreibung
a_x	Beschleunigung in x-Richtung
a_y	Beschleunigung in y-Richtung
$E[v_x]$	Erwartungswert der Geschwindigkeit in x-Richtung
$E[v_y]$	Erwartungswert der Geschwindigkeit in y-Richtung
$Var[v_x]$	Varianz der Geschwindigkeit in x-Richtung
$Var[v_y]$	Varianz der Geschwindigkeit in y-Richtung
$E[a_x]$	Erwartungswert der Beschleunigung in x-Richtung
$E[a_y]$	Erwartungswert der Beschleunigung in y-Richtung
$Var[a_x]$	Varianz der Beschleunigung in x-Richtung
$Var[a_y]$	Varianz der Beschleunigung in y-Richtung

Tabelle 6.1: Gespeicherte Objektmerkmale (nach [Dol05])

wobei das Umfeldbeschreibungs-/Vorhersage-Modul die jeweiligen aktuellen Erwartungswerte

aus den Werten der Vergangenheit bzw. die Erwartungswerte der Varianz berechnet. Von der daran anschließenden Prädiktion zukünftiger Objektzustände schließt das Modul bereits einige Objekte aus, die ganz offensichtlich nicht als relevant in Frage kommen:

1. **Objekte mit zu geringer Relativgeschwindigkeit** stellen keine Gefährdung dar, für die die Auslösung einer Aktuatorik wie zum Beispiel reversible Gurtstraffer notwendig wäre.
2. **Objekte mit negativer x -Koordinate** haben bereits den von dem System überwachten Frontbereich des Fahrzeugs verlassen.
3. **Objekte, deren Zustand nicht CONFIRMED ist**, bieten keine ausreichende Datenbasis, die zu einer sicheren Entscheidung notwendig ist.
4. **Objekte, die das Sichtfeld verlassen**, bieten ebenfalls keine verlässliche Datenbasis, da die Anzahl der vom Laserscanner gelieferten Messwerte rapide abnimmt und damit keine sichere Entscheidung ermöglicht.
5. **Objekte mit zu großen Varianzen in Geschwindigkeit oder Beschleunigung** kann das System aufgrund zu unsicherer Daten nicht berücksichtigen.

Für die verbleibenden Objekte berechnet das System den Zeitpunkt, an dem die Objekte die y -Achse des Koordinatensystems überqueren. Voraussetzung zur Bestimmung dieses Zeitpunktes sind die Erwartungswerte von Geschwindigkeit und Beschleunigung

$$E[v_x] = \sum_{i=0}^{F-1} w_{k-i} \cdot v_{x,k-i} \quad (6.1)$$

$$E[a_x] = \sum_{i=0}^{F-2} \frac{v_{x,k-i} - v_{x,k-i-1}}{T}, \quad (6.2)$$

ermittelt unter gewichteter Einbeziehung der gespeicherten Momentanwerte, ausgehend vom aktuellen Zeitpunkt k . Die Festlegung einzelner Gewichte kann anhand der vom Kalman-Filter gelieferten Schätzfehler mit

$$w_{k-i} = \frac{\sum_{j=0; j \neq i}^{F-1} \sigma_{v_{x,k-j}}^2}{\sum_{j=0}^{F-1} \sigma_{v_{x,k-j}}^2}, \quad (6.3)$$

abhängig vom Alter der Werte entsprechend

$$w_{k-i} = \frac{\frac{F}{i}}{\sum_{j=1}^F \frac{F}{j}} \quad (6.4)$$

oder gleichmäßig nach

$$w_{k-i} = \frac{1}{F} \quad (6.5)$$

erfolgen. Dabei gilt für alle w_{k-i} :

$$\sum_{i=0}^{F-1} w_{k-i} = 1. \quad (6.6)$$

Der Zeitpunkt t_c , der bei einem bevorstehenden Unfall der Zeit bis zum Beginn der Kollision ($t_c = 0$) entspräche, ergibt sich dann mit dem Lösen der Gleichung

$$0 = x_k + t_c \cdot E[v_x] + \frac{1}{2} t_c^2 \cdot E[a_x] \quad (6.7)$$

zu

$$t_{c1,2} = \frac{-E[v_x] \pm \sqrt{E[v_x]^2 - 2E[a_x]x}}{E[a_x]}. \quad (6.8)$$

Bei einer großen negativen Beschleunigung, bei der das Objekt noch vor Erreichen der y -Achse zum Stehen kommt, gibt es keine reelle Lösung. Daher sortiert das System alle Objekte aus, für deren Beschleunigungswert nicht gilt:

$$E[a_x] : x < \frac{E[v_x]^2}{2E[a_x]}. \quad (6.9)$$

Ist der Zeitraum t_c bis zur Kollision größer als der im System festgelegte Zeitschwellwert t_{sc} zur Auslösung (siehe Abschnitt 1.3), verwirft das Modul das betreffende Objekt ebenfalls. Ein nächstes, wichtiges Kriterium zur Vorauswahl eines Objektes ist der Punkt, an dem das Objekt die y -Achse erreicht. Mit dem Kollisionszeitpunkt t_c , den y -Komponenten von Geschwindigkeit und Beschleunigung

$$E[v_y] = \sum_{i=0}^{F-1} w_{k-i} \cdot v_{y,k-i} \quad (6.10)$$

$$E[a_y] = \sum_{i=0}^{F-2} \frac{v_{y,k-i} - v_{y,k-i-1}}{T} \quad (6.11)$$

ergibt sich dieser Punkt aus

$$y_c = y_k + t_c \cdot E[v_y] + \frac{1}{2} t_c^2 \cdot E[a_y]. \quad (6.12)$$

Die Gewichte p_i sind analog Gleichung 6.3, 6.4 oder 6.5 zu berechnen. Befindet sich der Punkt y_c nicht innerhalb der Fahrzeuggrenzen, so ist das entsprechende Objekt zu verwerfen. Alle nun noch verbleibenden Objekte werden entsprechend der betrachteten Informationen und der physikalischen Gesetzmäßigkeiten innerhalb der Zeitschwelle t_{sc} mit dem eigenen Fahrzeug kollidieren. Die Umfeldbeschreibungs-/Vorhersage-Stufe stellt diese potentiell gefährlichen Objekte der Entscheidungsstufe zur Verfügung.

6.2 Entscheidungsverfahren in Einzelsensorsystemen

Im Falle korrekt ermittelter Objektparameter durch vorgeschaltete Signalverarbeitungsstufen wäre die Ermittlung von Objekten, mit denen das eigene Fahrzeug kollidieren wird, nach dem im vorherigen Abschnitt 6.1 beschriebenen Ablauf abgeschlossen. Entsprechend der physikalischen Gesetzmäßigkeiten kollidiert das Objekt mit dem Fahrzeug innerhalb der Zeitspanne t_c am Ort y_c . Reale Umfelderkennungssysteme können aber nicht immer alle Objektparameter korrekt ermitteln. Fehler treten größtenteils durch stark verrauschte Messungen, schwankende Qualität der Messungen, fehlerhafte Zuordnungen oder durch von den verwendeten Algorithmen bedingte Schwachstellen bei der Signalverarbeitung auf. Diese Probleme bedingen vor allem ungenügend gefilterte Bewegungsverläufe bis hin zu kurzzeitigem „Springen“ und führen damit zu Falschalarmen (siehe Def. 1.1). Viele dieser Falschalarme lassen sich durch die gezielte Untersuchung bestimmter Parameter erkennen und ausfiltern. Die folgenden zwei Abschnitte beschreiben zwei mögliche Vorgehensweisen zur Erkennung von Falschalarmen in einem Einzelsensorsystem.

6.2.1 Entscheidung mittels Limit

Die Grundidee eines auf *Limits* basierenden Systems ist das Verteilen von *Strafpunkten*. Der Entscheider verteilt Strafpunkte anhand verschiedener Tests. Für die Bewertung eines Objekts stehen N Tests zur Verfügung. Innerhalb jedes Tests kann das System mehrere Attribute bzw. Eigenschaften prüfen. Die Anzahl zu prüfender Eigenschaften während eines Tests i ist mit $n_i, i \in \{1, \dots, N\}$ bezeichnet. Das Objekt besitzt damit eine entsprechende Anzahl von Attributen

$$v_{1,1}, \dots, v_{1,n_1}, \dots, v_{N,1}, \dots, v_{N,n_j},$$

wobei $v_{i,l}$ Attribut l im Test i entspricht. Die Prüfung dieser Werte erfolgt durch den Vergleich mit festgelegten Grenzwerten

$$c_{1,1}, \dots, c_{1,n_1}, \dots, c_{N,1}, \dots, c_{N,n_j}.$$

Falls ein Objekt während eines Tests „durchfällt“ bekommt es einen Strafpunkt p_i , welcher in r_i gespeichert wird:

$$r_i = \begin{cases} p_i & \text{für } v_{i,1} > c_{i,1}, \dots, v_{i,n_j} > c_{i,n_j} \\ 0 & \text{sonst.} \end{cases} \quad (6.13)$$

Nach dem Durchlauf aller Tests bzw. dem Vergleich aller Attribute erfolgt ein letzter Test mit einer auf die Gesamtheit der Testparameter bezogenen Schwelle L , bei dem das betreffende Objekt im Falle von

$$\sum_{i=1}^N r_i > L \quad (6.14)$$

für den aktuellen Zeitschritt zu verwerfen ist. Verbleibende Objekte sind damit als „Crash-Objekte“ bestimmt und die Entscheidungsstufe leitet die entsprechenden Informationen zusammen mit einem Auslösebefehl an eine Aktuatorik weiter.

Die korrekte Auswahl der zu überprüfenden Parameter und deren erlaubte Grenzwerte ist der schwierigste Teil dieses Ansatzes. Geeignete Attribute sind die Varianzen von Geschwindigkeit und Beschleunigung, Objektlebensdauer, Anzahl der Zyklen, in dem das betreffende Objekt bereits als kritisch eingestuft wurde als auch daraus kombinierte Werte. Die Bestimmung der Grenzwerte kann mittels Optimierungsverfahren wie zum Beispiel *Simulated Annealing* oder *genetischen Algorithmen* [MC96, LSAD04] erfolgen. Auf Limits basierende Entscheidungsverfahren sind sehr einfach zu implementieren und auch nicht sehr rechenaufwändig, haben aber den Nachteil, dass sie die Merkmale nur einzeln und nicht in ihrem Gesamtzusammenhang bzw. als Muster betrachten.

6.2.2 Entscheidung mittels Klassifikation

Ein zweiter Ansatz zur Erkennung von durch Fehler in Messung oder Signalverarbeitung bedingten Falschauslösungen ist die Verwendung eines Klassifikators. Im Unterschied zu Verfahren, die anhand einzelner Limits fehlerhafte Entscheidungen vermeiden sollen, betrachten Klassifikatoren diese Merkmale in ihrer Gesamtheit bzw. als Muster. Derartige Merkmale können, wie bereits in Abschnitt 6.2.1 aufgeführt, Varianzen von Geschwindigkeit und Beschleunigung, Objektlebensdauer, Anzahl der Zyklen, in dem das betreffende Objekt bereits als kritisch eingestuft wurde oder auch daraus kombinierte Werte sein. Ein für das vorgestellte PreCrash-System verwendeter, reduzierter Satz von Attributen

$$\mathbf{z} = \begin{pmatrix} z_1 \\ z_2 \\ z_3 \end{pmatrix} \quad (6.15)$$

besteht beispielsweise aus [Dol05, Mol05]:

$$z_1 = \sigma_{v_x} \quad (6.16)$$

$$z_2 = \frac{n_h}{F} \quad (6.17)$$

$$z_3 = \frac{n_w}{F}, \quad (6.18)$$

mit der Varianz der Geschwindigkeit in x -Richtung σ_{v_x} , der Anzahl $n_h, n_h \in \{0, \dots, F\}$ der beobachteten Zyklen bzw. Lebensdauer, der Anzahl $n_w, n_w \in \{0, \dots, F\}$ der Zyklen, in denen das Objekt als kritisch einzustufen war und der Länge des Beobachtungsfensters F . Ein Klassifikator soll nun anhand der so erzeugten Merkmalsvektoren für jeden Zeitschritt in zwei Klassen K_1 (für „Objekt kollidiert mit eigenem Fahrzeug“) und K_2 (für „Objekt kollidiert nicht mit eigenem Fahrzeug“) unterscheiden können. Ein hierfür aufgrund von Robustheit und Schnelligkeit geeignetes Klassifikationsverfahren ist der *Bayes-Klassifikator* [Sch96]. Dieser Klassifikator bestimmt die bedingte Wahrscheinlichkeit, dass ein Objekt bei gegebenem Merkmal \mathbf{z} zu der Klasse K_1 gehört:

$$P(K_1|\mathbf{z}) = \frac{P(\mathbf{z}|K_1)P(K_1)}{P(\mathbf{z})} \quad (6.19)$$

$$= \frac{P(z_1, z_2, z_3|K_1)P(K_1)}{P(z_1, z_2, z_3|K_1)P(K_1) + P(z_1, z_2, z_3|K_2)P(K_2)}. \quad (6.20)$$

Unter der Annahme, dass alle Attribute voneinander bedingt unabhängig sind¹ und für die Auftretenswahrscheinlichkeiten der beiden Klassen

$$P(K_1) = P(K_2) \quad (6.21)$$

gilt, ergibt sich aus Gleichung 6.20 folgende vereinfachte Form

$$P(K_1|\mathbf{z}) = \frac{\prod P(z_j|K_1)}{\prod P(z_j|K_1) + \prod P(z_j|K_2)}, \quad (6.22)$$

die nur noch die auf die einzelnen Elemente j des Merkmalsvektors bezogenen bedingten Wahrscheinlichkeiten $P(z_j|K_1)$ und $P(z_j|K_2)$ benötigt. Zur Ermittlung dieser bedingten Wahrscheinlichkeiten dienen Histogramme. Deren Häufigkeiten sind für die Intervalle innerhalb des Attribut-Wertebereiches durch Messungen realer Objekte in möglichst vielen unterschiedlichen Situationen zu erfassen.

Im Falle von

$$P(K_1|\mathbf{z}) > 0,5 \quad (6.23)$$

ist das betreffende Objekt als „Crash-Objekt“ bestimmt und die Entscheidungsstufe sendet einen Auslösebefehl zusammen mit entsprechenden Informationen an die Aktuatorik.

6.3 Entscheidungsverfahren bei mehreren Sensoren

6.3.1 Klassifikation und logische Verknüpfung

Wie in Abschnitt 6.2 bereits beschrieben, reicht allein die Bestimmung der Parameter t_c und y_c für eine verlässliche Funktion eines PreCrash-Systems nicht aus. Fehler durch verrauschte Messungen, schwankende Messqualität, fehlerhafte Zuordnungen in der Assoziationsstufe oder Schwachstellen in den verwendeten Algorithmen würden Falschalarme hervorrufen. Eine auf Limits oder Klassifikatoren beruhende Entscheidungsstufe kann durch derartige Effekte hervorgerufene Falschalarme ausfiltern. Falschalarme können jedoch aus einer weiteren Fehlerquelle resultieren. So detektieren reale Sensoren zeitweise Ziele, die entweder gar nicht existieren oder deren Detektion komplett unerwünscht ist. Solche Ziele werden oft als „Geisterziele“ bezeichnet. Vor allem Radarsensoren liefern gelegentlich Detektionen, die von Mehrfachreflexionen oder Objekten wie Gullydeckeln herrühren. Aber auch Laserscanner sind nicht ganz frei von solchen Problemen: Hier sind in seltenen Fällen Nebel- oder Rauchschwaden (beispielsweise Fahrzeugabgase) Ursache für Geisterziele. Die Einbeziehung bzw. Fusion mehrerer Sensoren, die ein gemeinsames Umfeld überwachen, bietet ein Mittel, derartige Falschalarme zu erkennen und auszufiltern.

Die Realisierung eines solchen Entscheiders erfolgt zweistufig: Eine erste Stufe, basierend auf einem in Abschnitt 6.2.2 beschriebenen Bayes-Klassifikator, filtert alle Objekte aus, deren Einordnung als „kollidierendes Objekt“ durch Fehler bei Messung, Zuordnung oder Signalverarbeitung bedingt ist. Eine zweite Stufe fusioniert die Sensoren zur Erkennung von Geisterzielen. Ein einfacher Ansatz zur Fusion der Sensorik ist die Verwendung von logischen

¹Die Unabhängigkeit ist in der Regel schwer nachweisbar, die Richtigkeit der Annahme ist jedoch letztendlich an der Klassifikationsleistung erkennbar [Sch96].

Verknüpfungen wie zum Beispiel

$$S = S_{LMS} \wedge (S_{R1} \vee S_{R2}). \quad (6.24)$$

Die Entscheidung für oder gegen die Existenz S eines Objekts resultiert hier aus der Verknüpfung der Entscheidungen jedes Sensors S_{LMS} , S_{R1} und S_{R2} . Die Grundlage solcher Entscheidungen bilden dabei die einem Objekt zugehörigen Anzahlen $n_h, n_h \in \{0, \dots, F\}$ von Detektionen innerhalb eines Zeitfensters F durch die unterschiedlichen Sensoren. Die jeweilige Anzahl von Detektionen durch einen Sensor ist dabei in Ablehnung oder Zustimmung der Objektexistenz für jeden Sensor einzeln umzurechnen:

$$S_{LMS} = \begin{cases} 1 & \text{für } n_{h,LMS} \leq n_{s,LMS} \\ 0 & \text{sonst} \end{cases} \quad (6.25)$$

$$S_{R1} = \begin{cases} 1 & \text{für } n_{h,R1} \leq n_{s,R1} \\ 0 & \text{sonst} \end{cases} \quad (6.26)$$

$$S_{R2} = \begin{cases} 1 & \text{für } n_{h,R2} \leq n_{s,R2} \\ 0 & \text{sonst} \end{cases}, \quad (6.27)$$

unter Beachtung der sensorspezifischen Schwellwerte $n_{s,LMS}$, $n_{s,R1}$ und $n_{s,R2}$ mit

$$n_{s,LMS}, n_{s,R1}, n_{s,R2} \in \{0, \dots, F\}. \quad (6.28)$$

In einem letzten Schritt verknüpft der Entscheidungsalgorithmus die Aussage des Bayes-Klassifikators (C , quantisiert entsprechend Ausdruck 6.23 zu $C \in \{0, 1\}$) mit der Aussage der Sensorik und löst damit im Falle von

$$S \wedge C = 1 \quad (6.29)$$

aus.

Ein solches Verfahren ist einfach und sehr schnell. Es beachtet aber Informationen zu Betriebszuständen wie zum Beispiel Sensorverschmutzung oder ungünstige Geschwindigkeitsbereiche nur ungenügend bzw. bietet keine konzeptionelle Basis für die Einbeziehung solcher Informationen. Das Ergebnis einer solchen Vorgehensweise ist zudem aufgrund der starken Quantisierung nicht optimal.

6.3.2 Klassifikation und Dempster-Shafer-Kombination

Die Einbeziehung bekannter Zusatzinformationen kann bei der Entscheidung bezüglich der Objektexistenz helfen, den Beitrag eines Sensors zu bewerten und damit die Leistung der Entscheidungsstufe zu verbessern. Derartige Zusatzinformation kann zum Beispiel aus dem Wissen bestehen, dass ein bestimmter Sensor ausgefallen oder in seiner Detektionsleistung beeinträchtigt ist. Eine andere Information kann eine Objektgeschwindigkeit sein, bei der ein Sensor unter Umständen Schwierigkeiten hat, ein Objekt verlässlich zu detektieren. Eine geeignete Verknüpfungsvorschrift sollte dann neben einer Aussage bezüglich der Objektexistenz auch eine auf den Zusatzinformationen basierende Bewertung des Ergebnisses liefern. Eine

Verwendung von Fuzzy-Verfahren [Bec05] oder klassischer wahrrscheinlichkeitstheoretischer Verfahren ist prinzipiell möglich. Eine besonders geeignete Methode zur Umsetzung dieser Strategie bzw. der Modellierung solcher Zusammenhänge ist jedoch die im Folgenden kurz beschriebene *Evidenztheorie*.

Dempster-Shafer-Theorie

Die *Evidenztheorie* bzw. *Dempster-Shafer-Theorie* geht auf die Arbeiten von DEMPSTER und SHAFER zurück [Dem68, Sha76] und ist eine Verallgemeinerung der Wahrscheinlichkeitstheorie. Ziel dieser Theorie ist die Modellierung von *Unsicherheiten*. Diese Unsicherheiten resultieren zum einen aus unzuverlässigen Quellen und zum anderen aus ungenügendem oder fehlendem Wissen über Beziehungen zwischen Ursachen und Effekten. Ungewissheiten sind durch „Grade des Glaubens“ (*belief*) quantifiziert und verschiedenen Hypothesen zugeordnet. Das Verfahren berücksichtigt somit Wissen und Nichtwissen.

Die Evidenztheorie betrachtet hierfür eine endliche Menge Θ von N Vorschlägen bzw. Beobachtungen a_1, a_2, \dots, a_N , auch als *Hypothesenraum* oder *Frame of Discernment* bezeichnet. Eine Potenzmenge 2^Θ entspricht der Menge aller Teilmengen von Θ . Das Gegenstück zur Verteilungsdichtefunktion der Wahrscheinlichkeitstheorie ist die Massefunktion der Evidenztheorie, eine Funktion $m : 2^\Theta \rightarrow [0, 1]$ mit folgenden Eigenschaften:

$$m(\emptyset) = 0 \quad (6.30)$$

$$\sum_{X \subseteq \Theta} m(X) = 1, \quad (6.31)$$

wobei \emptyset die leere Menge darstellt. Die Masse $m(X)$ repräsentiert den Grad des Glaubens an die Aussage X mit $X \subseteq \Theta$. Jede Teilmenge $X \subseteq \Theta$, für die

$$m(X) > 0 \quad (6.32)$$

gilt, wird als *fokales Element* bezeichnet. Der *Kern* einer Massefunktion m ist definiert als

$$c := \bigcup_{X: m(X) > 0} X \quad (6.33)$$

und stellt die Vereinigungsmenge aller fokalen Elemente dar.

Die Summe aller Massen, die durch einen Sensor einer Annahme zugeordnet sind, spiegelt den Glauben (*Belief*) $Bel(a)$ für diese Annahme wider; oft auch als *Support* $S(a)$ bezeichnet:

$$Bel(a) = \sum_{X \subseteq a} m(X). \quad (6.34)$$

Die Summe aller Massen, die nicht der Negation einer Annahme zugeordnet sind, entspricht der *Plausibility*:

$$Pl(a) = 1 - S(\bar{a}). \quad (6.35)$$

Diese lässt sich auch durch Summation aller Massen einschließlich $m(\Theta)$ berechnen, die mit a und seinen Verknüpfungen verbunden sind, wie zum Beispiel

$$Pl(a_1) = m(a_1) + m(a_1 \cup a_2) + m(a_1 \cup a_3) + \dots + m(\Theta). \quad (6.36)$$

Ein *Unsicherheitsintervall* bzw. *Uncertainty Interval* ist schließlich durch

$$[S(a), Pl(a)] \quad \text{mit} \quad S(a) \leq Pl(a) \quad (6.37)$$

definiert. Eine grafische Darstellung dieser Zusammenhänge an einem Beispiel befindet sich in Abbildung 6.2.

Die Kombination zweier Massefunktionen m_1 und m_2 ist durch die *Dempster's rule of com-*




Abbildung 6.2: Zusammenhang von Massefunktion, Glaubens- und Plausibilitätsgrad

bination bzw. *Dempster-Kombinationsregel* wie folgt definiert:

$$m(c) = m_1 \oplus m_2 = \frac{\sum_{\{i,j:a_i \cap b_j=c\}} m_1(a_i) \cdot m_2(b_j)}{1 - K} \quad (6.38)$$

und ist für unabhängige Quellen anwendbar. Dabei ist K ein Maß für den Widerspruch:

$$K = \sum_{\{i,j:a_i \cap b_j=\emptyset\}} m_1(a_i) \cdot m_2(b_j). \quad (6.39)$$

Die Kombinationsregel ist sowohl kommutativ als auch assoziativ einsetzbar:

$$m_1 \oplus m_2 = m_2 \oplus m_1 \quad (6.40)$$

$$(m_1 \oplus m_2) \oplus m_3 = m_1 \oplus (m_2 \oplus m_3). \quad (6.41)$$

Der wichtigste Unterschied zwischen Evidenztheorie und klassischer Wahrscheinlichkeitstheorie besteht in der Modellierung der Unsicherheit. Im Gegensatz zur Wahrscheinlichkeitstheorie lässt es die Evidenztheorie zu, dass den Elementen a_1 und a_2 einer Menge Θ die Masse

$$m(a_1) = m(a_2) = 0, \quad (6.42)$$

der Menge $(a_1 \cup a_2)$ jedoch eine Masse

$$m(a_1 \cup a_2) > 0 \quad (6.43)$$

zugewiesen werden kann. Das ermöglicht die Modellierung der Ungewissheit über das Eintreten der Ereignisse a_1 und a_2 . Ebenso ist der Ausdruck vollständiger Unwissenheit möglich:

$$Bel(X) = \begin{cases} 1 & \text{für } X = \Theta \\ 0 & \text{für } X \neq \Theta. \end{cases} \quad (6.44)$$

Eine Massefunktion geht dann in eine Verteilungsdichtefunktion über, wenn die Massen nur auf die Elemente a_i der Menge Θ mit $a_i \in \Theta$ und nicht auf Teilmengen a_j von Θ mit $a_j \subseteq \Theta$ verteilt sind. Das bedeutet, dass bei einer nicht vorhandenen Unsicherheit ($S(a_i) = PL(a_i)$ bzw. $S(a_i) = 1 - S(\bar{a}_i)$) und fehlendem a priori-Wissen $P(a_i) = 0,5$ die Ergebnisse der Verknüpfungen nach Dempster-Kombinationsregel und Bayes'schem Theorem identisch sind [LVMD05].

Ein Problem bei der Anwendung der Dempster-Kombinationsregel kann bei der Verknüpfung stark widersprüchlicher Datenquellen ($K \approx 1$) entstehen: Das Ergebnis der Verknüpfung ist dann unlogisch. Derartige Komplikationen entstehen jedoch meistens bei falscher Modellierung [Hae05]. In weiterführenden Arbeiten entstanden Ansätze wie die *Fixsen-Mahler Modified Dempster Shafer Theory* [FM97], die *Dezert-Smarandache Theory* [Dez02] oder der *Generalized Belief Fusion Algorithm* [Sud03], die unter anderem die Probleme bei stark widersprüchlichen Datenquellen lösen sollen.

Anwendung der Evidenztheorie in der Entscheidungsstufe

Wie auch bei der Verwendung einer logischen Verknüpfungsregel ist die Entscheidungsstufe für das Multisensorsystem zweigeteilt: Die erste Stufe basiert auf einem in Abschnitt 6.2.2 beschriebenen Bayes-Klassifikator und filtert alle Objekte aus, deren Einordnung als „kollidierendes Objekt“ durch Fehler bei Messung, Zuordnung oder Signalverarbeitung bedingt ist. Die zweite Stufe fusioniert die Sensoren zur Erkennung von Geisterzielen unter Verwendung der Dempster-Shafer-Theorie.

Für jeden Sensor ist hierfür ein Hypothesenraum $\Theta_s = \{S, \bar{S}\}$ definiert, in dem die Hypothesen S für „existierendes Objekt“ und \bar{S} für „nicht existierendes Objekt“ stehen. Daraus ergibt sich eine Potenzmenge $2_s^\Theta = \{S, \bar{S}, S \cup \bar{S}, \emptyset\}$. Deren Elemente sind mit Ausnahme der leeren Menge \emptyset durch die Massefunktionen der Sensoren jeweils einer Masse zugeordnet. Im Falle des Laserscanners erhalten dessen Aussagen eine Unsicherheit, die sich beispielsweise aus einer Statistik bezüglich der Detektionsleistungen im normalen Betrieb unter Berücksichtigung aller Verarbeitungsschritte bis zur Entscheidungsstufe herleiten lässt:

$$m_{LMS}(S \cup \bar{S}) = c_{LMS,b}. \quad (6.45)$$

Die Massefunktion für die Hypothese „existierendes Objekt“ leitet sich aus dem Verhältnis der Anzahl von Detektionen eines Objekts $n_{h,LMS}$ zur Lebensdauer des Objekts n_h ab [Dol05]:

$$m_{LMS}(S) = \frac{\sum_{i=0}^{n_h} 2^{n_h-i} \cdot n_{h,LMS}[i]}{\sum_{i=0}^{n_h} 2^{n_h-i}} \cdot (1 - m_{LMS}(S \cup \bar{S})). \quad (6.46)$$

Hierbei ist in $n_{h,LMS}[i]$ die Aussage zum Zeitpunkt i enthalten, ob der Laserscanner eine Detektion geliefert hat oder nicht ($n_{h,LMS}[i] \in \{0, 1\}$). Die Formel berücksichtigt dabei jüngere Zeitpunkte exponentiell stärker als ältere. Der Term $(1 - m_{LMS}(S \cup \bar{S}))$ dient der Normierung, da gelten muss:

$$m_{LMS}(S) + m_{LMS}(\bar{S}) + m_{LMS}(S \cup \bar{S}) = 1. \quad (6.47)$$

Die restliche Masse ist dann der Ablehnung der Objektexistenz zuzuordnen:

$$m_{LMS}(\bar{S}) = 1 - (m_{LMS}(S) + m_{LMS}(S \cup \bar{S})). \quad (6.48)$$

Die Bestimmung der Massefunktionen für die Radarsensoren erfolgt analog:

$$m_R(S \cup \bar{S}) = c_{R,b} \quad (6.49)$$

$$m_R(S) = \frac{\sum_{i=0}^{n_h} 2^{n_h-i} \cdot n_{h,R}[i]}{\sum_{i=0}^{n_h} 2^{n_h-i}} \cdot (1 - m_R(S \cup \bar{S})) \quad (6.50)$$

$$m_R(\bar{S}) = 1 - (m_R(S) + m_R(S \cup \bar{S})). \quad (6.51)$$

Die Unsicherheit $c_{R,b}$ der verwendeten Radarsensoren liegt unter anderem aufgrund der stärker ausgeprägten Geisterzielproblematik höher als die des Laserscanners. Zudem ist die Detektionsleistung der verwendeten Prototypen bei steigender Objektgeschwindigkeit stark vermindert, was eine lineare Anpassung von $c_{R,b}$ an die Relativgeschwindigkeit des beobachteten Objekts notwendig macht.

Bei Erkennung einer verschlechterten Detektionsleistung oder eines Sensorausfalls sind die Unsicherheiten der Sensoren $m_{LMS}(S \cup \bar{S})$ und $m_R(S \cup \bar{S})$ entsprechend zu erhöhen. Zu beachten ist jedoch, dass bei Totalausfall eines Sensors die Leistung des Gesamtsystems derartig gemindert werden kann, dass eine ausreichend sichere Entscheidung nicht mehr möglich ist. Im beschriebenen System ist das bei Komplettausfall des Laserscanners oder beider Radare gleichzeitig der Fall, da das System dann nicht mehr in der Lage ist, Geisterziele sicher zu erkennen und auszufiltern.

Die Fusion der durch die einzelnen Sensoren bestimmten Massen erfolgt in mehreren Stufen (assoziativ) unter Verwendung der Dempster-Kombinationsregel. Ein erster Schritt verknüpft die Massen m_{R1} und m_{R2} der Radarsensoren zu fusionierten Massen m_t :

$$m_t(S) = \frac{m_{R1}(S)m_{R2}(S) + m_{R1}(S)m_{R2}(S \cup \bar{S}) + m_{R2}(S)m_{R1}(S \cup \bar{S})}{1 - (m_{R1}(S)m_{R2}(\bar{S}) + m_{R1}(\bar{S})m_{R2}(S))} \quad (6.52)$$

$$m_t(\bar{S}) = \frac{m_{R1}(\bar{S})m_{R2}(\bar{S}) + m_{R1}(\bar{S})m_{R2}(S \cup \bar{S}) + m_{R2}(\bar{S})m_{R1}(S \cup \bar{S})}{1 - (m_{R1}(S)m_{R2}(\bar{S}) + m_{R1}(\bar{S})m_{R2}(S))} \quad (6.53)$$

$$m_t(S \cup \bar{S}) = \frac{m_{R1}(S \cup \bar{S})m_{R2}(S \cup \bar{S})}{1 - (m_{R1}(S)m_{R2}(\bar{S}) + m_{R1}(\bar{S})m_{R2}(S))}. \quad (6.54)$$

In einem nachfolgenden Schritt fusioniert die Entscheidungsstufe die Massen m_{LMS} des Laserscanners mit den Massen m_t zu den kombinierten Massen m_s aller Sensoren:

$$m_s(S) = \frac{m_t(S)m_{LMS}(S) + m_t(S)m_{LMS}(S \cup \bar{S}) + m_{LMS}(S)m_t(S \cup \bar{S})}{1 - (m_t(S)m_{LMS}(\bar{S}) + m_t(\bar{S})m_{LMS}(S))} \quad (6.55)$$

$$m_s(\bar{S}) = \frac{m_t(\bar{S})m_{LMS}(\bar{S}) + m_t(\bar{S})m_{LMS}(S \cup \bar{S}) + m_{LMS}(\bar{S})m_t(S \cup \bar{S})}{1 - (m_t(S)m_{LMS}(\bar{S}) + m_t(\bar{S})m_{LMS}(S))} \quad (6.56)$$

$$m_s(S \cup \bar{S}) = \frac{m_t(S \cup \bar{S})m_{LMS}(S \cup \bar{S})}{1 - (m_t(S)m_{LMS}(\bar{S}) + m_t(\bar{S})m_{LMS}(S))}. \quad (6.57)$$

Die Massen m_s enthalten nun die Entscheidung des Sensorsystems bezüglich der Existenz eines beobachteten Objekts. Bei stark widersprüchlichen Sensordaten ($K \approx 1$) und daraus resultierenden unlogischen Ergebnissen muss die Entscheidungsstufe die Unsicherheit zu $m_s(S \cup \bar{S}) = 1$ (komplett unsicher) setzen.




Abbildung 6.3: Der Hypothesenraum des Entscheidungssystems

In einem letzten Schritt fusioniert die Entscheidungsstufe nun die Sensorentscheidung bezüglich der Objektexistenz mit der Entscheidung des Bayes-Klassifikators zur Wahrscheinlichkeit eines Unfalls mit diesem Objekt zu einer Bewertung der Aussage „existierendes und kollidierendes Objekt“ (vgl. auch Abbildung 6.3). Ein Äquivalent für diese Aussage ist die Masse $m(S \cap C)$. Dabei entspricht S der Hypothese eines *existierenden* Objekts und C der Hypothese eines *kollidierenden* Objekts. Für die Ergebnisse des Bayes-Klassifikators ist hierfür ein Hypothesenraum $\Theta_b = \{C, \bar{C}\}$ definiert. Die Entscheidungsstufe rechnet die Ausgaben des Bayes-Klassifikators nach folgenden Formeln in Massen um:

$$m_b(C) = P(K_1 | z) \quad (6.58)$$

$$m_b(\bar{C}) = P(K_2 | z) = 1 - m_b(C) \quad (6.59)$$

$$m_b(C \cup \bar{C}) = 0. \quad (6.60)$$

Die Masse für die Unsicherheit $m_b(C \cup \bar{C})$ ist gleich Null, da keine zusätzlichen Unsicherheiten der auf Statistiken basierenden Klassifikation bekannt sind. Die kombinierte Masse $m(S \cap C)$ ergibt sich letztendlich zu

$$m(S \cap C) = m_b(C) \cdot (m_s(S) + m_s(S \cup \bar{S})). \quad (6.61)$$

Gilt für die resultierende Masse

$$m(S \cap C) > 0,5 \quad (6.62)$$

und gibt es außerdem keinen Komplettausfall des Laserscanners oder beider Radare gleichzeitig, löst der Entscheidungsalgorithmus aus.

Ein so mit Hilfe der Evidenztheorie realisierter Entscheidungsalgorithmus erfordert nur wenig mehr Rechenleistung als das auf Logik basierende Verfahren (siehe Abschnitt 6.3.1).

Zudem ist aufgrund der fehlenden Quantisierung mit besseren Ergebnissen zu rechnen. Eine Schwierigkeit eines solchen Ansatzes besteht jedoch in der Auswahl geeigneter Massefunktionen und in der Anpassung der zahlreichen Parameter.

7 Ergebnisse

Auf Basis der in Kapitel 1 beschriebenen Funktionalität und der daraus resultierenden Anforderungen zeigen die Abschnitte 4 bis 6 verschiedene Ansätze zur Realisierung eines PreCrash-Systems auf. Die prinzipiellen Vor- und Nachteile der verschiedenen Verfahren hinsichtlich ihrer Eignung für ein PreCrash-System im Automobilbereich sind ebenso aufgeführt. Der nun folgende Abschnitt zeigt und vergleicht die mit ausgewählten Verfahren erreichten Ergebnisse.

Die Grundlage für Vergleiche und Bewertungen bieten aufgenommene Messdaten, aber auch simulierte Daten. Ein erster Abschnitt beschreibt diese Daten in ihrer Art und ihrem Umfang. Dieser Ausführung schließt sich ein kurzer, wiederholender Überblick zum Aufbau des PreCrash-Systems und zu den für die Tests verwendeten Algorithmen an. Darauf folgen Abschnitte, die Ergebnisse einzelner Signalverarbeitungsstufen, so beispielsweise vom Tracking-Modul oder der Sensorausfall-Erkennung, aber auch Aussagen zur Gesamtleistung des PreCrash-Systems in Abhängigkeit von Fusionsansatz und gewähltem Entscheidungsverfahren beinhalten.

7.1 Randbedingungen

7.1.1 Datensätze

Eine wichtige Größe bei der Bewertung eines Systems ist die Qualität der Testdaten. Sie bestimmt maßgeblich die Aussagekraft der Ergebnisse und Vergleiche. Die aufgenommenen oder simulierten Messdaten sollten daher

- die Erreichung besonders wichtiger Ziele wie zum Beispiel Robustheit und Zuverlässigkeit des Systems dokumentieren können,
- eine Bestimmung grundlegender Systemeigenschaften wie Genauigkeit und Geschwindigkeit ermöglichen,
- die Grenzen des Systems aufzeigen
- und dabei eine ausreichende Basis für statistische Aussagen bieten.

Während der Arbeiten an dem PreCrash-System stand für die Aufnahme von Messdaten ein Versuchsfahrzeug zur Verfügung, mit welchem Daten aus realen Fahrsituationen gesammelt werden konnten. Daneben war eine Simulationsumgebung inklusive eines Laserscanner-Sensormodells verfügbar. Die so gewonnenen Daten lassen sich in die folgenden Kategorien einteilen:

Normalfahrten Die aufgenommenen Messdaten stammen aus realen Fahrsituationen innerhalb von Städten, auf Landstraßen oder Autobahnen. Die Wetterbedingungen waren meistens gut und schränkten die Detektionsleistungen der Sensoren daher kaum ein. Das Sammeln solcher Daten dient vor allem dem Aufbau einer Datenbasis zur Bewertung des Systems hinsichtlich der *Falschalarmrate* (siehe Def. 1.1 auf Seite 20).

Kritische Situationen Diese Kategorie enthält Messungen während kritischer Fahrmanöver, beispielweise sehr knappe Vorbeifahrten bei hohen Geschwindigkeiten, Ausweichmanöver oder Vollbremsungen vor Objekten. In keinem Fall kam es zu einem Zusammenstoß mit einem Objekt. Messungen von kritischen Situationen dienen ebenso der Erfassung der Falschalarmrate. Daneben zeigen sie auch die Genauigkeit der Ergebnisse interner Verarbeitungsschritte, beispielsweise zur Bewertung der Qualität der Objektverfolgung.

Unfallsituationen Für die Aufnahme von Daten verschiedener Unfallsituationen erfolgten Versuche mit Schaumstoff- oder Papp-Objekten (Abbildung 7.1). Diese wurden bei verschiedenen Geschwindigkeiten, unter verschiedenen Anfahrwinkeln (Einlenken) und teilweise inklusive vorheriger Vollbremsung durchgeführt. Entsprechend der Systemanforderungen decken die Messungen einen Geschwindigkeitsbereich von 20 km/h bis 150 km/h ab. Daten aus diesen Messreihen dienen zur Bestimmung der *Detektionsrate* bzw. der *Fehlalarmrate* (siehe Def. 1.2 auf Seite 21).



Abbildung 7.1: Testobjekte für Unfallszenarien

Spezialfälle Messungen dieser Kategorie beinhalten eine Vielzahl von Situationen. Verfügbar sind Messungen von Unfallsituationen bei ungünstigen Wetterbedingungen wie Schnee, Regen oder Nebel oder auch bei verschmutztem Sensor¹. Weiterhin enthalten sind Messungen während normaler Fahrsituationen mit ungünstigen Wetterbedingungen oder verschmutztem Sensor, Messungen mit stehendem Fahrzeug und bewegten Objekten und Messungen mit

¹Die „Verschmutzung“ wurde durch Abkleben von Teilbereichen des Laserscanners simuliert.

stark negativ beschleunigten Objekten. Die Messungen innerhalb dieser Kategorie dienen vor allem der Bewertung der Ergebnisse von Zwischenstufen wie dem Tracking-Modul oder der Sensorausfallerkennung hinsichtlich ihrer Genauigkeit bzw. Erkennungsleistung.

Simulierte Daten Während der Arbeiten standen nur simulierte Daten des Laserscanners zur Verfügung. Der Einsatz solcher Daten beschränkte sich auf die Bestimmung von Systemgrenzen hinsichtlich der maximal verarbeitbaren Relativgeschwindigkeit und zur Untersuchung der adaptiven Anpassung von \mathbf{Q} im Tracking-Algorithmus.

Die Anzahl von Tests innerhalb von Unfallsituationen beträgt 116. Kritische Situationen sind 33mal in der Datenbasis enthalten. Die gesamte Zeitdauer der Messungen beträgt ca. 11 Stunden und 36 Minuten. Aus diesen Zahlen ist bereits ersichtlich, dass die vorhandene Datenmenge keine ausreichende Basis für statistische Bewertungen oder Aussagen darstellt. Sie kann bestenfalls Trends liefern oder Probleme aufzeigen. Daher lag auch der Fokus bei Aufnahme von Unfallsituationen vor allem auf der Erfassung möglichst vieler schwieriger Situationen, um einen Gewinn an Robustheit durch die Fusion von Sensoren darstellbar zu machen.

7.1.2 Systemstruktur und Algorithmen

In den Kapiteln 4 bis 6 wurden einige mögliche Varianten zur Realisierung von Signalverarbeitungsstufen vorgestellt, eine Vorauswahl sinnvoller Lösungsansätze ist in den entsprechenden Abschnitten bereits angedeutet. Die letztendlich für das PreCrash-System und dessen Bewertung bzw. Vergleiche genutzten Algorithmen sind im Folgenden für die einzelnen Signalverarbeitungsstufen noch einmal zusammenfassend aufgeführt:

Segmentierungsstufe Für die Segmentierungsstufe kommt ein gitterbasiertes Segmentierungsverfahren zum Einsatz. Die Zellengröße des Gitters ist auf die Erfordernisse des Systems und die Rahmenbedingungen im automobilen Umfeld abgestimmt: Die Ausdehnung der Zellen besitzt in r -Richtung im sehr nahen und sehr fernen Bereich eine feste Größe, im mittleren Bereich ist die Ausdehnung an die in Abschnitt 4.2.1 beschriebenen geometrischen Eigenschaften des Messverfahrens angepasst. Die Größe der Winkelschritte ist nach außen hin ansteigend. Die Extraktion von Merkmalen geschieht nach der Drei-Punkte-Methode.

Tracking-Stufe Die Tracking-Stufe besteht aus einem Kalman-Filter mit dem in Kapitel 4.3.2 vorgestellten Systemmodell. Für die Erreichung einer kurzen Reaktionszeit des Systems bei neuen Objekten dient die in Abschnitt 4.3.4 beschriebene Vorgehensweise beim Aufsetzen eines neuen Tracks. Eine adaptive Kovarianzmatrix \mathbf{Q} verbessert die Anpassung des Systemmodells an das reale Objektverhalten. Eine adaptive Kovarianzmatrix \mathbf{R} berücksichtigt sowohl durch unterschiedliche Messgenauigkeiten in verschiedenen Sichtbereichen auftretende Fehler als auch den Fehler, der durch die fehlende Berücksichtigung der einzelnen Anteile der Messfehler bei der Transformation der Messwerte von Polarkoordinaten in kartesische Koordinaten entstehen würde. Eine Eigenbewegungskompensation ist aufgrund der in 4.3.4 beschriebenen Problematik nicht implementiert.

Entscheidungsstufe Für ein Einzelsensorsystem ist die Entscheidung mit Hilfe eines Bayes-Klassifikators die implementierte Vorgehensweise, bei Verwendung mehrerer Sensoren fusioniert das Modul zusätzlich die Sensoraussagen bezüglich der Objektexistenz – entweder mittels einfacher Logik nach 6.3.1 oder dem in Kapitel 6.3.2 vorgestellten Ansatz auf Grundlage der Evidenztheorie.

Sensorausfallerkennung Die Art der Einflüsse auf das Sensorsystem und die daraus resultierenden Fehler machen einen Einsatz modellbasierter Verfahren sehr schwierig. Bekannte modellfreie Verfahren finden nur einige bestimmte Fehler und benötigen oft zusätzliche, hier nicht zur Verfügung stehende Information. Die Realisierung der Sensorausfallerkennung erfolgt daher mittels des in Abschnitt 4.4.3 vorgestellten Ansatzes.

Fusionsmodul Verwendete Fusionansätze sind die in Kapitel 5.3 beschriebenen Gitter- bzw. Messvektorfusionsverfahren. Hierbei findet die Fusion entweder in der Segmentierungsstufe oder im Tracking-Modul statt. Die Entscheidungsstufe fusioniert außerdem die Aussagen der Sensoren bezüglich der Objektexistenz.

7.2 Ergebnisse und Vergleich

7.2.1 Tracking-Algorithmus

Für den Test des Tracking-Algorithmus kamen verschiedene, unter anderem in Abbildung 7.1 dargestellte, statische Objekte zum Einsatz. Zu testende Eigenschaften waren die korrekte algorithmische Funktion, die Grenzen des Systems, die Schätzgenauigkeit, das korrekte Verfolgen von Objekten und der Einfluss durch die Adaptivität der Systemfehlerkovarianzmatrix Q .

Tests mit realen und simulierten Messdaten zeigten eine korrekte Funktion des Tracking-Algorithmus bis zu Relativgeschwindigkeiten von 200 km/h. Die Grundlage zur Abdeckung eines Geschwindigkeitsbereiches von 20 km/h bis 150 km/h ist damit gegeben.

Erwartungsgemäß zeigte sich die Abhängigkeit der Schätzgenauigkeit von der Bestimmung eines stabilen Objekt-Referenzpunktes. Es erfolgten Tests, bei dem sich sowohl kleine als auch ausgedehnte Objekte in x - und auch in y -Richtung am Fahrzeug vorbeibewegten. Innerhalb ausgedehnter Objekte (z. B. Auto) verschiebt sich der als Referenzpunkt gewählte Schwerpunkt in Abhängigkeit vom Blickwinkel des Sensors. Bei einer Vorbeifahrt in x -Richtung ist dieser Effekt besonders ausgeprägt. Die aus der Verschiebung des Schwerpunktes resultierenden Einflüsse auf die Geschwindigkeitsschätzung sind in Abbildung 7.2 für zwei Objekte unterschiedlicher Größe dargestellt. Der Fehler der Geschwindigkeitsschätzung für das ausgedehnte Objekt ist deutlich sichtbar. Ein Indiz für einen solchen Fehler stellt auch die normierte quadratische Innovation dar, die aufgrund der konstanten Geschwindigkeiten sehr klein sein müsste, für das ausgedehnte Objekt jedoch kurzzeitig große Werte erreicht (Abbildung 7.3). Diese großen Werte resultieren aus der Abweichung der Prädiktion vom gemessenen Referenzpunkt durch die zu diesem Zeitpunkt auftretende Verschiebung. Bei einer Vorbeifahrt in horizontaler Richtung treten diese Probleme nur stark vermindert auf, beispielsweise wenn ein




Abbildung 7.2: Auswirkungen der Referenzpunktverschiebungen auf die Geschwindigkeitsschätzung für zwei Objekttypen (beginnend mit Überquerung der x -Achse) [Dol05]

ausgedehntes Objekt den Sichtbereich des Sensors verlässt. Für die Anwendung sind Fehler in der Geschwindigkeitsschätzung bei Vorbeifahrten in y -Richtung unkritisch, da sich potentiell gefährliche Objekte immer relativ zum eigenen Fahrzeug hinbewegen und dabei in der Regel nur geringe Ungenauigkeiten auftreten.

Die Adaption der Systemfehlerkovarianz zur verbesserten Anpassung des Tracking-Verfahrens an das aktuelle Objektverhalten war Gegenstand eines weiteren Tests: Ein im Simulator erzeugtes Objekt bewegte sich mit einer Geschwindigkeit in x -Richtung von 100 km/h auf das eigene Fahrzeug zu, verzögerte dann mit einer negativen Beschleunigung von -15 m/s^2 bis es zum Stehen kam, beschleunigte wieder in Gegenrichtung bis zu einer Geschwindigkeit von 50 km/h und bewegte sich schließlich aus dem Sichtfeld der Sensoren. Ein Resultat zu niedriger, auf konstante Geschwindigkeiten eingestellter Systemkovarianzen ist in Abbildung 7.4 dargestellt. Niedrige Systemfehlerkovarianzen führen entsprechend Gleichung 5.25 auf Seite 105 zu kleinen Suchbereichen. Die Prädiktion ist wegen des zugrundeliegenden Systemmodells während starker Beschleunigungsphasen ungenau. Das Kalman-Filter wichtet die Prädiktion zu hoch, was im Zusammenspiel mit einem zu kleinen Suchbereich die Zuordnung einer zugehörigen Messung bereits nach einer sehr kurzen Anzahl von Messzyklen verhindert. Der Schätzfehler steigt durch fehlende Messungen immer weiter an, bis der Tracking-Algorithmus schließlich das Objekt aufgrund wiederholt fehlender Messungen verwirft. Das Filter muss immer wieder neue Objekte anlegen und kann dadurch keine stabile Verfolgung inklusive verlässlicher Bewegungsinformationen liefern. Im Gegensatz dazu bewirken große, auf maximale Beschleunigungen ausgelegte Werte für Systemfehlerkovarianzen eine schlechte Glättung bzw. Rauschfilterung bei den zumeist vorkommenden konstanten Relativgeschwindigkeiten. Ein Test derselben Situation mit adaptiven Systemfehlerkovarianzen zeigt die Fähigkeit des Filters, nun das Objekt über seine gesamte Aufenthaltsdauer im Sichtbereich der Sensoren zu verfolgen. Bei steigenden Werten der normierten quadratischen Innovation reagiert das Filter mit einer Vergrößerung der Systemfehlerkovarianzen, ausgehend von einem an konstante Be-




Abbildung 7.3: Normierte quadratische Innovation bei Vorbeifahrt in x -Richtung: ausgedehntes Objekt links und kleines Objekt rechts (beginnend mit Überquerung der x -Achse) [Dol05]




Abbildung 7.4: Fehler bei Objektverfolgung durch zu kleine Systemfehlerkovarianzen [Dol05]

wegungen angepassten Wert. Zurückgehende Werte der normierten quadratischen Innovation führen wiederum zu einer Absenkung der Systemfehlerkovarianzen auf den Ursprungswert. Abbildung 7.5 zeigt sowohl die durchgehende Verfolgung der Objektbewegung während des Manövers als auch die dabei auftretenden Werte der normierten quadratischen Innovation. Abbildung 7.6 verdeutlicht noch einmal die Wirkung angepasster Systemfehlerkovarianzen an unterschiedlichen Bewegungsphasen: Während eine große Systemfehlerkovarianz innerhalb von Beschleunigungsphasen ein Sterben von Objekten verhindert und zu einer schnellen Anpassung an das reale Objektverhalten führt, ist die Glättungswirkung während konstanter Bewegungsabschnitte nur gering. Eine kleine Systemfehlerkovarianz wiederum bedingt neben einer verminderten Fähigkeit des Filters, das Objekt während seiner gesamten Aufenthaltsdauer zu verfolgen, auch eine träge Reaktion auf Bewegungsänderungen. Die Glättungswirkung während konstanter Bewegungen ist jedoch ausreichend. An die Objektbewegungen




Abbildung 7.5: Objektverfolgung und normierte quadratische Innovation bei Objektmanövern und adaptiven Systemfehlerkovarianzen [Dol05]




Abbildung 7.6: Rauschglättung und Dynamik während unterschiedlicher Bewegungsphasen [Dol05]

bzw. deren Änderungen angepasste Systemfehlerkovarianzen kombinieren die positiven Eigenschaften beider Auslegungsformen.

7.2.2 Sensorausfallerkennung

Die Zielstellung dieser Komponente ist die Erkennung eines Ausfalls oder einer signifikanten Verschlechterung der Detektionsleistung eines Sensors. Im Fahrzeugumfeld wirken ständig Einflüsse wie Erschütterungen, Verschmutzung, Temperaturschwankungen und Feuchtigkeit auf die Sensoren ein. Vor allem die sehr häufig auftretenden Verschmutzungen beeinträchtigen optische Systeme in ihrer Funktion. Die Erkennung solcher Fälle stellte das Testszenario für das im Kapitel 4.4.3 vorgestellte Verfahren dar. Messfahrten mit teilweise (auch mehrfach) abgeklebtem Laserscanner durch verschiedene Szenarien boten die Grundlage für eine

erste Bewertung des Ansatzes hinsichtlich der Fehl- und Falschalarmrate. Die Datenbank umfasst Stadtfahrten, Fahrten auf Landstraßen und Autobahnen in etwa gleichen Verhältnissen. Die Fehlererkennung bezog während der Versuche nur die Daten des Laserscanners in die Verarbeitung ein. Das Sichtfeld des Laserscanners war in drei Gebiete mit getrennter Ausfallerkennung unterteilt, die wiederum jeweils drei virtuelle Sensoren enthielten (siehe auch Abbildung 4.20 auf Seite 94). Die Einbeziehung mehrerer Zeitfenster in die Fehlererkennung geschah gewichtet.

Abbildung 7.7 zeigt ein Beispiel für einen Fehlerfall. Zu erkennen ist der zeitweise, durch




Abbildung 7.7: Beispiel für einen gleichzeitigen Ausfall zweier Sensoren [Uzu05b]

Abkleben erzeugte Ausfall von zwei virtuellen Sensoren. Die Anzahl von Messereignissen ist im Gegensatz zu denen der anderen virtuellen Sensoren deutlich niedriger bzw. es sind keine Messereignisse vorhanden, was einen starken Anstieg des Ausfallzählers d_k bewirkt (vgl. Ausdruck 4.125 auf Seite 93). Eine weitere Abbildung 7.8 verdeutlicht durch verschiedene Szenarien hervorgerufene Unterschiede im Ergebnis während der Überwachung funktionstüchtiger Sensoren: Innerhalb bebauter Gebiete bewegen sich in der Regel viele Ziele durch die Sichtbereiche der virtuellen Sensoren, was die Anzahl der Zeitfenster gering hält, in denen ein virtueller Sensor signifikant weniger Ziele als andere virtuelle Sensoren detektieren konnte. Auf Autobahnen hingegen kann es über längere Zeit zu Situationen kommen, in denen sich keine Objekte durch die Sichtfelder der virtuellen Sensoren bewegen. Das führt bei funktionstüchtigen Sensoren zu größeren Werten von d_k im Vergleich zu Innenstadtszenarien. Dies ist bei der Einstellung der Schwellwerte für d_k zu beachten. Eine Erweiterung der in Abbildung 4.18 auf Seite 93 dargestellten Funktion zur Anpassung der Fensterbreite um einen Anstieg bei sehr hohen Geschwindigkeiten hingegen erscheint nicht sinnvoll, da der Zusammenhang zwischen Geschwindigkeit und durchschnittlicher Anzahl von Objekten im Sichtbereich innerhalb von Autobahnszenarien nicht gleichermaßen wie innerhalb von Innenstadtszenarien gilt. Während der Versuche erwies sich die Unterteilung der Überwachungsbereiche in Gebiete mit nahezu gleichverteilten Auftretenswahrscheinlichkeiten von Objekten als sinnvolle, die Robustheit des Verfahrens verbessernde Lösung.

Bezüglich der Fehl- und Falschalarmrate ergaben sich folgende erste Ergebnisse: Das Fehlererkennungsverfahren erkannte alle durch Abkleben des Sensors provozierten Ausfälle. Das Abkleben mehrerer Gebiete gleichzeitig verursachte ebenfalls keine Fehlalarme. Falschalarme

kamen in Abhängigkeit von der gewählten Breite des Zeitfensters F und dem Schwellwert η vor (Abbildung 7.9). Bei genügend langer Beobachtungsdauer traten bei den Tests al-




Abbildung 7.8: Werte des Ausfallzählers d_k innerhalb unterschiedlicher Szenarien (links: Autobahn, rechts: Innenstadt) [Uzu05b]




Abbildung 7.9: Auf die Messzyklen bezogene Falschalarmrate der Sensorausfallerkennung in Abhängigkeit von der Fensterbreite F (links: Schwellwert $\eta = 5$, rechts: Schwellwert $\eta = 15$)

lerdings keine Falschalarme mehr auf. Allerdings benötigt der Algorithmus dann auch eine längere Zeit, um einen Ausfall zu detektieren. In Abbildung 7.9 ist weiterhin zu erkennen, daß Falschalarme wie erwartet vor allem im mittleren Bereich des Sensorsichtbereiches (entspricht virtuellen Sensoren 4, 5 und 6) auftreten, da hier typischerweise weniger Ziele als im Randbereich erscheinen.

Die genannten Werte sind jedoch aufgrund der geringen Anzahl vorhandener Messungen nicht als endgültige Aussagen zu Fehl- und Falschalarmrate zu interpretieren. Vielmehr zeigen

sie die grundlegende Fähigkeit des vorgestellten Algorithmus, Sensorausfälle im Fahrzeugumfeld prinzipiell detektieren zu können.

7.2.3 Gewinn an Robustheit durch Fusion

Eines der wichtigsten Ziele der Arbeiten war die Verbesserung der Robustheit des Gesamtsystems gegenüber externen Einflüssen auf die Sensoren, wie sie im automobilen Umfeld häufig auftreten. Durch Einsatz von Verfahren zur Sensordatenfusion sollten sich die Detektionen der einzelnen Sensoren gegenseitig „ergänzen“ und so zwischenzeitliche Detektionsprobleme einzelner Sensoren ausgleichen. Der Effekt ist unter anderem deutlich bei der Verfolgung eines Objekts durch die Tracking-Stufe zu beobachten.

Ein Versuch, der den Gewinn durch die Fusion der Sensoren verdeutlicht, wurde folgendermaßen durchgeführt: Ein Versuchsfahrzeug fuhr mit nahezu konstanten 40 km/h gegen eine Schaumstoffsäule. Dabei war das Sichtfenster des Laserscanners teilweise abgeklebt, um eine Verschmutzung zu simulieren. Abbildung 7.10 und 7.11 zeigen jeweils x -Positionen bzw. y -Positionen der Tracks und der zugeordneten Messungen über der Zeit. Das Fehlen von Daten




Abbildung 7.10: Objektverfolgung mit Fusion bei verschmutztem Laserscanner (x -Koordinate, links Rohdaten allein, rechts Rohdaten und Track) [Dol05]

des Laserscanners innerhalb eines bestimmten Bereiches ist deutlich zu erkennen. Dieser Bereich ist durch das Abkleben des Scanners abgeschattet. Der Tracking-Algorithmus ist in der Lage, unter Einbeziehung von Daten mehrerer Sensoren eine stabile Objektverfolgung über eine lange Zeitdauer zu gewährleisten. Die Geschwindigkeitsschätzung bleibt trotz des Ausfalls von Messwerten recht konstant (Abbildung 7.12). Derartige Tests wurden auch bei ungünstigen Wetterbedingungen wie zum Beispiel Schneefall mit ähnlichen Ergebnissen durchgeführt. Ein Einzelsensorsystem auf Basis eines Laserscanners könnte unter solchen Bedingungen aufgrund des sehr späten Einsetzens erster Detektionen keine verlässliche Erkennung von Unfallsituationen sicherstellen. Weitere Problemfälle für die Erkennung von Unfallsituationen sind Situationen mit niedrigen Relativgeschwindigkeiten, da aufgrund der Sensorabdeckung und der daraus resultierenden Reflexion des Signals an dieser der Sensor Objekte erst ab einer bestimmten Mindestentfernung detektieren kann. Bei niedrigen Relativgeschwindigkeiten führt dies zu einem Sterben des Objekts, noch bevor es die Auslöseschwelle r_c erreicht.




Abbildung 7.11: Objektverfolgung mit Fusion bei verschmutztem Laserscanner (y -Koordinate, links Rohdaten allein, rechts Rohdaten und Track) [Dol05]




Abbildung 7.12: Geschwindigkeitsschätzung bei verschmutztem Laserscanner für x - und y -Komponente [Dol05]

Auch bei diesen Situationen hilft die Fusion mit zusätzlicher Sensorik, die Objektverfolgung bis zur Auslöseschwelle stabil aufrechtzuerhalten.

7.2.4 Entscheidungsstufe und Gesamtfunktionalität

Die Leistungen des Gesamtsystems zeigen sich in letzter Konsequenz am Ausgang des Systems bzw. am Ausgang der Entscheidungsstufe. Hier sind die grundlegend korrekte Funktion der Algorithmen, die Genauigkeit der Schätzwerte sowie die Fehl- und Falschalarmraten die wichtigsten Parameter zur Bewertung der Systemleistung.

Die korrekte Funktion aller implementierten Algorithmen wurde unter Verwendung einer Vielzahl von Versuchen gezeigt. Die Genauigkeit der Schätzwerte ist mit den gegebenen Mess-

Kategorie	Anzahl	Gesamtzeit	Falschauslösungen	Fehlauflösungen
Crash-Tests	110	00:48:38.92s	-	28
Beinahe-Crashes	33	00:07:59.00s	0	-
Landstraße	90	04:07:30.88s	0	-
Autobahn	41	02:05:16.08s	0	-
Innenstadt	61	02:35:11.84s	0	-
Sonstige	47	01:51:57.60s	0	-
Summe	382	11:36:34.32s	0	28

Tabelle 7.1: Versuchsergebnisse des Einzelsensorsystems (Laserscanner und Bayes-Klassifikator)

mitteln nicht zuverlässig bestimmbar. Während der Versuche fehlten Einrichtungen, um die berechneten Werte mit externen Messungen zu vergleichen. Zudem ist die Abtastzeit der Sensoren im zur Verfügung stehenden System nur mit einer der Zykluszeit T entsprechenden Genauigkeit ermittelbar. Die Auslegung des Systems erfolgte daher ohnehin auf eine (für die meiste Aktuatorik unkritische) um $2 \cdot T$ vorverlegte Auslösung (siehe auch Kapitel 5.1). Die ausreichende Schätzgenauigkeit der Geschwindigkeitsschätzung und der Positionsschätzung durch den Tracking-Algorithmus ist weiterhin Grundlage und gleichzeitig ein Indiz für eine ausreichend genaue Bestimmung der Unfallparameter.

Die Bestimmung der Fehl- und Falschalarmraten erfolgte für ein Einzelsensorsystem auf Basis des Laserscanners und für das Multisensorsystem mit unterschiedlichen Fusionsansätzen und Entscheidungsalgorithmen. Die wichtigsten Ergebnisse dieser Tests sind in den folgenden Abschnitten zusammengefasst. Grundlage aller Tests waren dabei immer die in Abschnitt 7.1.1 beschriebenen realen Messdaten. Daher ist die Aussagekraft der Versuche nur sehr begrenzt; sie können allenfalls Trends oder deutliche Unterschiede zwischen den einzelnen Ansätzen zeigen.

Einzelsensorsystem

Stellvertretend für ein Einzelsensorsystem wurden Versuche auf Basis eines Laserscanners und eines aus einem Bayes-Klassifikator bestehenden Entscheidungsalgorithmus (siehe Abschnitt 6.2.2 auf Seite 116) durchgeführt. Dieser Bayes-Klassifikator findet so auch in dem Multisensorsystem Anwendung. Das Training des Bayes-Klassifikators geschah unter der Verwendung von Histogrammen, die allerdings nur auf einem kleinen Teil der aufgenommenen Messdaten basierten. Die Ergebnisse der Versuche sind in Tabelle 7.1 aufgeführt. Falschauslösungen gibt es bei dieser Konfiguration nicht, jedoch 28 Fehlalarme, was einer auf die Anzahl der Versuche bezogenen Rate von 25,5 % (Detektionsrate 74,5 %) entspricht. Die Rate ist erwartungsgemäß hoch, da vor allem die Messdaten von Unfallsituationen bewusst zu einen großen Teil unter erschwerten Bedingungen (Verschmutzung, ungünstige Wetterbedingungen) aufgenommen wurden.

Kategorie	Anzahl	Gesamtzeit	Falschauslösungen	Fehlauslösungen
Crash-Tests	110	00:48:38.92s	-	14
Beinahe-Crashes	33	00:07:59.00s	0	-
Landstraße	90	04:07:30.88s	3	-
Autobahn	41	02:05:16.08s	0	-
Innenstadt	61	02:35:11.84s	0	-
Sonstige	47	01:51:57.60s	1	-
Summe	382	11:36:34.32s	4	14

Tabelle 7.2: Versuchsergebnisse des Multisensorsystems (Bayes-Klassifikator und Logikentscheidung, Variante 1)

Kategorie	Anzahl	Gesamtzeit	Falschauslösungen	Fehlauslösungen
Crash-Tests	110	00:48:38.92s	-	16
Beinahe-Crashes	33	00:07:59.00s	0	-
Landstraße	90	04:07:30.88s	0	-
Autobahn	41	02:05:16.08s	0	-
Innenstadt	61	02:35:11.84s	0	-
Sonstige	47	01:51:57.60s	1	-
Summe	382	11:36:34.32s	1	16

Tabelle 7.3: Versuchsergebnisse des Multisensorsystems (Bayes-Klassifikator und Logikentscheidung, Variante 2)

Entscheidungsalgorithmen für Multisensorsysteme

Kapitel 6.3 auf Seite 117 stellte zwei unterschiedliche Vorgehensweisen zur Entscheidungsfindung bei Multisensorsystemen vor. Beiden gemein ist der Bayes-Klassifikator, der die Entscheidung bezüglich der Kollisionswahrscheinlichkeit trifft. Unterschiede bestehen zwischen den Verfahren bei der Entscheidung zur Objektexistenz. Die Tests erfolgten mit zwei Varianten der einfachen Logikentscheidung auf Grundlage des Messvektor-Fusionsansatzes: In Variante 1 muss der Laserscanner mindestens einmal während der Objektlebensdauer eine Detektion geliefert haben ($n_{s,LMS} = 1$ in Gleichung 6.25), anderenfalls verwirft der Entscheider das Objekt. Die Ergebnisse in Tabelle 7.2 zeigen, dass die Anzahl der Fehlauslösungen deutlich auf 14 bzw. auf eine Rate von 12,7 % (Detektionsrate 87,3 %) zurückgegangen ist. Deutlich sichtbar ist der Beitrag der Radare zur Detektion von Objekten in der Fahrzeugumgebung unter schwierigen Bedingungen für den Laserscanner. Hinzugekommen sind allerdings auch 4 Falschalarme, die durch von den Radaren gelieferte Geisterziele entstanden sind. Eine Verschärfung der Regel für Variante 2 auf mindestens 7 Detektionen durch den Laserscanner ($n_{s,LMS} = 7$ in Gleichung 6.25) für eine positive Entscheidung brachte das in Tabelle 7.3 zusammengestellte Resultat. Hier steigt die Anzahl der Fehlalarme auf 16 bzw. die Fehlalarmrate auf 14,5 % (Detektionsrate 85,5 %), dafür sinkt die Anzahl der Falschalarme auf

Kategorie	Anzahl	Gesamtzeit	Falschauslösungen	Fehlauslösungen
Crash-Tests	110	00:48:38.92s	-	16
Beinahe-Crashes	33	00:07:59.00s	0	-
Landstraße	90	04:07:30.88s	0	-
Autobahn	41	02:05:16.08s	0	-
Innenstadt	61	02:35:11.84s	0	-
Sonstige	47	01:51:57.60s	0	-
Summe	382	11:36:34.32s	0	16

Tabelle 7.4: Versuchsergebnisse des Multisensorsystems (Bayes-Klassifikator und Dempster-Shafer-Verfahren)

Kategorie	Anzahl	Gesamtzeit	Falschauslösungen	Fehlauslösungen
Crash-Tests	110	00:48:38.92s	-	17
Beinahe-Crashes	33	00:07:59.00s	0	-
Landstraße	90	04:07:30.88s	0	-
Autobahn	41	02:05:16.08s	0	-
Innenstadt	61	02:35:11.84s	0	-
Sonstige	47	01:51:57.60s	0	-
Summe	382	11:36:34.32s	0	17

Tabelle 7.5: Versuchsergebnisse des Multisensorsystems (Fusionsansatz Segmentierungsgitter, Bayes-Klassifikator und Dempster-Shafer-Verfahren)

1. Das Ergebnis ist jedoch nicht akzeptabel, da ein Auftreten von Falschalarmen bei der kurzen Gesamtfahrzeit von ca. 11 Stunden und 36 Minuten bereits auf eine hohe zu erwartende Falschalarmrate hindeutet. Zudem läuft eine Regel von mindestens 7 Detektionen den Anforderungen nach einer möglichst schnellen Reaktion des Systems auf kritische Situationen zuwider.

Die erwartete Verbesserung des Systemverhaltens ergab sich bei Einsatz des auf Evidenztheorie basierenden Verfahrens (Tabelle 7.4). Die Fehlalarmrate blieb bei 14,5 % (Detektionsrate 85,5 %), innerhalb des Versuchszeitraumes gab es jedoch keine Falschalarme mehr. Auch die durchschnittliche Reaktionszeit des Systems auf kritische Situationen dürfte kürzer als bei der Logikentscheidung Variante 2 sein, da hier die Zustimmung bzw. Ablehnung der Objektexistenz durch einen Sensor immer relativ zur Objektlebensdauer ermittelt wird.

Vergleich der Fusionsansätze

Weitere Versuche sollten die Unterschiede zwischen den unterschiedlichen Fusionsansätzen aufzeigen. Die Ergebnisse eines Multisensorsystems auf Basis der Messvektorfusion und einer Entscheidungsstufe, bestehend aus Bayes-Klassifikator und Dempster-Shafer-Verfahren, sind bereits in Tabelle 7.4 enthalten. Die Ergebnisse des zweiten, auf dem Segmentierungs-

gitter und gleicher Entscheidungsstrategie basierenden Fusionsansatzes sind in Tabelle 7.5 aufgeführt. Ein Vergleich der Fusionsansätze zeigt kaum Unterschiede bei der Fehlalarmrate; Falschalarme unterbleiben auch hier. Gründe für einzelne, hier aber nicht deutlicher darstellbare Unterschiede im Ergebnis der beiden Ansätze lägen vor allem in der Art der Assoziation der Messwerte der unterschiedlichen Sensoren. Ein daraus resultierendes Problem war bei sehr ungenauen Winkelangaben der Radare und Fusion innerhalb des Segmentierungsgitters zu beobachten. So verband der Algorithmus in einigen wenigen Fällen Messwerte des Laserscanners zu Segmenten, die nicht zusammengehörten, zwischen denen aber ein Radarziel lag. Derartige Probleme traten bei der Messvektorfusion und deren exklusiver Zuordnung der Radarmessungen zu Objekten nicht auf; hier liegt aber die Detektionsleistung des Gesamtsystems bei sehr schmalen oder schlecht vom Laserscanner detektierbaren Objekten aufgrund der fehlenden Berücksichtigung zusätzlicher Radarsensoren in der Segmentierungsstufe etwas niedriger.

Verbesserung nach Kategorien

Wie bereits in Abschnitt 7.2.3 gezeigt, verbessert die Fusion mehrerer Sensoren die Robustheit des Systems gegenüber Einzelsensorsystemen. Dies ist auch in dem Verhalten des Gesamtsystems bzw. in den Ausgaben der Entscheidungsstufe deutlich sichtbar. In Abbildung 7.13 ist hierfür eine in verschiedene Kategorien der Unfallsituationen unterschiedene Auswertung dargestellt. In der Auswertung sind die Ergebnisse des Einzelsensorsystems (Laserscanner




Abbildung 7.13: Fehlalarmraten nach Kategorie

und Bayes-Klassifikator) und des Multisensorsystems (Messvektorfusion, Bayes-Klassifikator und Dempster-Shafer-Verfahren) enthalten. Es zeigt sich, dass die Verbesserungen der Detektionsleistungen in Form stark verminderter Fehlalarmraten durch die Fusion vor allem im Bereich ungünstiger Wetterbedingungen, verschmutzter Sensoren und geringer Aufprallgeschwindigkeiten (aufgrund einer Sensorabdeckung ist eine große Mindestentfernung für Detektion durch Laserscanner notwendig) auftraten. Die Summe der Fehlalarmraten ergibt in dieser Darstellung nicht 100 %, da Unfallsituationen teilweise in mehreren Kategorien gleichzeitig enthalten sind. Das erklärt auch die Absenkung der Fehlalarmrate in der Kategorie „Aufprallwinkel“ (große Winkel). Im Falle sehr günstiger Bedingungen für den Laserscan-

ner („Sonstige“) ist wie erwartet keine Verbesserung des Systemverhaltens eingetreten. In der Kategorie „Hohe Geschwindigkeit“ ist ebenso keine Verbesserung eingetreten, da die verwendeten Radar-Prototypen bei sehr hohen Relativgeschwindigkeiten kaum noch Ziele detektieren konnten. Die allgemein hohe Fehlalarmrate bei Versuchen mit hoher Geschwindigkeit resultiert vor allem aus der schlechten Reflektivität und der geringen Größe der bei den Versuchen verwendbaren Pappziele.

8 Zusammenfassung

Der Inhalt dieser Arbeit besteht in der Vorstellung eines PreCrash-Systems; technische Grundlagen, Ansätze zur Signalverarbeitung und zur Fusion von Sensordaten stehen dabei im Vordergrund. Grundlage von Systemaufbau und Signalverarbeitung sind jedoch die Zielstellung eines solchen Systems und die daraus resultierenden Anforderungen an das System und die Sensorik: Ein PreCrash-System dient der Erkennung von bevorstehenden und unvermeidbaren Unfällen, mit dem Ziel, geeignete Sicherheitseinrichtungen schon vor dem Beginn des Aufpralls zu aktivieren oder durch ermittelte Unfallparameter vorzubereiten. Derartige Aktuatorik kann beispielsweise aus reversiblen Gurtstraffern bestehen, die schon vor dem Unfallbeginn straffen und die Passagiere besser mit dem Fahrzeug und dessen Beschleunigung verbinden. Zur Gewährleistung solcher und ähnlicher Funktionalität muss das PreCrash-System neben einer Entscheidung bezüglich eines bevorstehenden Unfalls auch wichtige Unfallparameter wie Geschwindigkeit, Beschleunigung, Zeit bis zum Aufprall oder den Aufprallort bereitstellen. Die Generierung solcher Informationen muss in allen Fahrsituationen und auch unter schwierigen Wetterbedingungen sichergestellt sein und darf auch aus Kostengründen nur möglichst wenig Rechenleistung beanspruchen. Dies erfordert eine robuste, genaue und schnelle Erfassung des Fahrzeugumfeldes. Ansätze zu Fahrzeugumfelderfassung gibt es bereits sehr viele; einige davon sind kurz aufgeführt. Im Gegensatz zu einem großen Teil der Arbeiten steht im vorgestellten System vor allem der Aspekt der Robustheit im Vordergrund. Die Fusion von Daten unterschiedlicher Sensoren stellt die Verwirklichung der aufgeführten Ziele in Aussicht. Es kommen dabei nur Sensoren in Betracht, die sich vor allem im Hinblick auf die Unempfindlichkeit gegenüber Wettereinflüssen gegenseitig ergänzen und deren Messverfahren daher auf unterschiedlichen physikalischen Grundlagen basieren, während sie aber ähnliche oder gleichartige Messdaten liefern. Die Wahl fiel auf einen Laserscanner mit mehreren Messebenen und zwei Nahbereichsradare, die zusammen mit einer Rechnerumgebung für Signalverarbeitung und Messdatenerfassung in einem Versuchsfahrzeug integriert wurden.

Die Beschreibung der physikalischen Grundlagen und der spezifischen Vor- und Nachteile der gewählten Sensorik ist ebenso in der Arbeit enthalten, wie eine Ausführung zu erwarteten Vor- und Nachteilen der Fusion gerade dieser beiden Sensortypen. Daneben sind die Zielstellungen, Grundlagen und eine Einordnung von Sensordatenfusion inklusive einem kurzen Überblick zu den am häufigsten verwendeten Werkzeugen beschrieben.

Ein besonders wichtiger Aspekt in einem Multisensorsystem ist die Signalverarbeitung, die neben dem eigentlichen Fusionsschritt, aber auch abhängig davon stattfinden muss. So sind für den Fall, dass die Radarsensoren ausschließlich Informationen zur Entfernung detektierter Objekte liefern, drei verschiedene Ansätze zur Fusion dieser Sensoren erläutert: Fusion mittels Triangulation, Einsatz des Grid of Evidence und die Verknüpfung der Sensoren mit Hilfe eines Klassifikators. Die Verfahren unterscheiden sich vor allem durch den Aufwand bei Implementierung und während des Betriebs und der Möglichkeit, Modellannahmen bezüglich

der detektierten Objekte zu integrieren. Allen gemeinsam fehlt selbstverständlich die Fähigkeit, aus der gegebenen Sensoranordnung resultierende Mehrdeutigkeiten aufzulösen.

Ein weiterer Teil der Signalverarbeitung ist die Vorverarbeitung der Laserscanner-Daten. Die Punkte sind in einem ersten Schritt realen Objekten in der Umgebung zuzuordnen, was über die Zusammenfassung von Punkten unter Berücksichtigung der geometrischen Eigenschaften des Messverfahrens und den Abmessungen erwarteter Objekte geschehen muss. Eine besondere Schwierigkeit war dabei die zusätzliche Verknüpfung der verschiedenen Messebenen des Laserscanners. Die optimale Ausnutzung der Detektionsleistungen aller Ebenen (bzw. Sensoren) stellte sich mit herkömmlichen, einfachen Verfahren als sehr schwierig heraus. Zudem sind die Anforderungen an die Rechenleistung sehr hoch. Ein angesichts dieser Probleme neu entwickelter, gitterbasierter Ansatz verknüpft die Daten der Sensoren unter vollständiger Einbeziehung der Detektionsleistungen, führt gleichzeitig die Segmentierung durch und beansprucht weniger Rechenleistung.

Das Verfolgen der Objekte und die Schätzung wichtiger Parameter wie Geschwindigkeit oder Position übernimmt ein Tracking-Filter. Grundlage hierfür ist ein lineares Kalman-Filter mit einem einfachen Systemmodell, welches an die Vielzahl vorkommender Objekte und deren unterschiedliche Bewegungsverläufe gleichermaßen ausreichend angepasst ist. Eine möglichst kurze Reaktionszeit des Systems auf neu detektierte Objekte ist gerade für ein PreCrash-System wichtig; das Aufsetzen eines neuen Tracks geschieht daher mit einem einfachen physikalischen Modell anstelle des Kalman-Filters. Um eine ausreichende Qualität der Schätzungen sowohl bei starken Beschleunigungen als auch während konstanter Bewegungsverläufe zu garantieren, verwendet das Tracking-Filter adaptive Systemkovarianzen. Die Erkennung der entsprechenden Objektmanöver geschieht mit Hilfe der normierten quadratischen Innovation. Aufgrund der ständigen Einwirkung von Umwelteinflüssen auf die Sensorik, ist die Erkennung einer verminderten Detektionsleistung oder eines kompletten Sensorausfalls eine wichtige Aufgabe bei der Bewertung der Qualität der Systemausgaben. Im automobilen Umfeld spielt dabei die Verschmutzung eine besonders große Rolle. Der Einsatz von modellbasierten Fehlererkennungsverfahren zur Erkennung von Ausfällen, die aus Verschmutzungen oder ähnlich wirkenden Ursachen resultieren, ist kaum praktikabel. Die Entwicklung von Modellen ist aufgrund der extremen Variabilität im Fahrzeugumfeld vorkommender Objekte und gleichzeitig unbekannten Eingangsgrößen kaum möglich. Bekannte modellfreie Verfahren erkennen daneben nur einige wenige Fehler und benötigen oft zusätzliche, am Ausgang der Sensoren in der Regel nicht zur Verfügung stehende Informationen. Dies machte die Entwicklung eines Ansatzes notwendig, der Ausfälle trotz aller Schwierigkeiten erkennt. Er basiert auf einfachen statistischen Funktionen und ist sowohl für den Laserscanner allein als auch für den Zusammenschluss aus Laserscanner und Nahbereichsradaren einsetzbar.

Die Fusion der Sensordaten geschieht mit dem Ziel, die Robustheit des Gesamtsystems zu erhöhen. Die Umsetzung der Zielstellung führt zu zwei Ansätzen, die besonders Elemente der konkurrierenden Fusion beinhalten. Aus einer Auswahl bekannter und für die Anwendung geeigneter Verfahren zur Sensordatenfusion wurde die Messvektor-Fusion als einfacher und schneller Vertreter ausgewählt und der Einsatz innerhalb des PreCrash-Systems ausführlich erläutert. In Konkurrenz dazu entstand ein weiterer Fusionsansatz, der die Radarmessungen schon innerhalb des Segmentierungsgitters mit den Daten des Laserscanners verknüpft, dadurch die Detektionsleistungen der einzelnen Sensoren zumindest potentiell besser nutzbar macht und den Umstand unterschiedlicher Objekt-Referenzpunkte besser berücksichtigt.

Thema weiterer Betrachtungen waren die zeitlichen Aspekte einer solchen Verknüpfung von Sensoren und deren Auswirkungen auf die zeitliche Auslegung von Systemaktionen.

Letzte Signalverarbeitungsschritte des hier vorgestellten PreCrash-Systems sind die Umfeldbeschreibungs-/Vorhersagestufe und eine Entscheidungsstufe. Beide Module stellen zugleich auch die anwendungsspezifischen Teile des Gesamtsystems dar. Während die Umfeldbeschreibungs-/Vorhersagestufe relevante Daten aller Objekte über längere Zeitverläufe speichert, Vorhersagen zu Aufenthaltsort, Geschwindigkeiten und Zeiten macht und bereits Kandidaten für eine Auslösung bereitstellt, trifft die Entscheidungsstufe die endgültige Entscheidung. Die Notwendigkeit eines zusätzlichen Entscheidungsschrittes ergibt sich aus Problemen, die von ungenauer Signalverarbeitung (beispielsweise schwankende Messqualität oder fehlerhafte Zuordnungen) oder falschen bzw. unerwünschten Detektionen (Geisterziele) herrühren. Diese würden bei fehlender Berücksichtigung zu einer erhöhten Falschalarmrate führen. Die Arbeit beschreibt Ansätze sowohl für Einzelsensorsysteme als auch für Multisensorsysteme. Bei Einzelsensorsystemen bietet sich neben der Extraktion geeigneter Merkmale eine Klassifikation zur Erkennung ungenauer Signalverarbeitungsergebnisse an. Der Einsatz mehrerer Sensoren macht zusätzlich das Verwerfen von Geisterzielen möglich. Die Evidenztheorie bietet – besonders bei Einbeziehung zusätzlicher Informationen wie zum Beispiel Sensorausfällen – ein sehr geeignetes Mittel zur Modellierung solcher Zusammenhänge.

Neben der Beschreibung der Algorithmen und der theoretischen Betrachtung deren Vor- und Nachteile ist der Test von Teilmodulen und des gesamten Systems unerlässlich. Die Grundlage hierfür bietet eine, aus realen Messdaten mit unterschiedlichen Verkehrssituationen und simulierten Daten bestehende Datenbasis. Aufgrund des geringen Umfangs der Datenbasis im Vergleich zu üblichen Fahrleistungen eines Fahrzeugs sind die Ergebnisse nicht als Statistik bezüglich der Fehl- und Falschalarmraten des PreCrash-Systems zu interpretieren. Ein weiterer Grund ist die Tatsache, dass vor allem die Daten der Unfallsituationen größtenteils unter schwierigen Bedingungen (ungünstiges Wetter, durch Abkleben simulierter Sensorausfall) zustande kamen, um eine Verbesserung der Robustheit des Multisensorsystems gegenüber eines Einzelsensorsystems demonstrieren zu können.

Bei den Tests der Einzelmodule zeigte sich die Wirkung der adaptiven Systemkovarianzen auf die Schätzgenauigkeit des Tracking-Algorithmus. Die Funktionstüchtigkeit des entwickelten Verfahrens zur Sensorausfallerkennung wurde ebenfalls anhand von Messungen mit speziell präpariertem Laserscanner nachgewiesen. Der Gewinn der Sensordatenfusion ist am Ausgang der Tracking-Stufe in Form stabil verfolgter Objekte auch bei fehlenden Detektionen einzelner Sensoren zu erkennen. Zudem sind die Fehlalarmraten des Multisensorsystems deutlich niedriger als die eines auf einem Laserscanner aufbauenden Einzelsensorsystems. Falschalarme traten bei dem Einzelsensorsystem nicht auf und waren auch im Multisensorsystem vermeidbar. Die Ergebnisse der beiden Fusionsansätze zeigen nahezu Gleichstand; mit der vorhandenen Datenbasis lassen sich keine größeren Unterschiede in der Qualität der Ergebnisse feststellen. Abstufungen bei der Zuverlässigkeit in Abhängigkeit vom eingesetzten Entscheidungsalgorithmus waren aber erkennbar. Hier bringt ein auf Evidenztheorie basierendes Verfahren bessere Ergebnisse als auf einfachen logischen Verknüpfungen beruhende Ansätze.

Für die Weiterentwicklung bzw. Verbesserung eines solchen PreCrash-Systems bieten sich verschiedene Ansätze an. Ein Beispiel hierfür ist die konsequente Einführung und stufen-

weise Weiterführung eines Vertrauensmaßes, das die endgültige Entscheidungsfindung unterstützt. In diesem Zusammenhang könnte ein Zweck zukünftiger Arbeiten auch darin bestehen, die Entwicklung von Ansätzen voranzutreiben, die Informationen der Sensorausfallerkennung noch besser in die einzelnen Signalverarbeitungsstufen einbeziehen. Auch sind Strategien denkbar, die unter bestimmten Bedingungen spezielle Algorithmen in Form einer Rückführung bzw. Rückführungsebenen starten, um eine bessere Ausnutzung der Detektionsleistungen der einzelnen Sensoren zu erreichen und die Zuverlässigkeit des Systems zu erhöhen.

Grundlage für eine bessere Bewertung der einzelnen Lösungsansätze kann nur eine stark erweiterte Datenbasis bieten.

Literaturverzeichnis

- [AHA05] ADOMEIT, Julius ; HAHN, Daniel ; ADOMEIT, Heinz-Dieter: Erhöhung des passiven Insassenschutzes durch Pre-Crash-Informationen – Potentiale reversibler Komponenten im Rückhaltesystem. In: *VDI-Berichte: Innovativer Kfz-Insassen- und Partnerschutz* Bd. 1911, VDI Verlag GmbH, 2005
- [Arc00] ARCHER, Jeff: Fundamental Traffic Safety issues Concerning the Use of Intelligent Transport Systems. In: *Publication of Royal Institute of Technology* (2000)
- [Bec02] BECKER, Jan C.: *Fusion der Daten der objekterkennenden Sensoren eines autonomen Straßenfahrzeugs*, Diss., 2002
- [Bec05] BECK, Sebastian: *Ein Konzept zur automatischen Lösung von Entscheidungsproblemen bei Unsicherheit mittels der Theorie der unscharfen Mengen und der Evidenztheorie*, Universität Karlsruhe (TH), Diss., 2005
- [BFhS96] BURGARD, Wolfram ; FOX, Dieter ; HENNIG, Daniel ; SCHMIDT, Timo: Estimating the Absolute Position of a Mobile Robot Using Position Probability Grids. In: *Proceedings of the Fourteenth National Conference on Artificial Intelligence*, 1996
- [BI97] BROOKS, Richard R. ; IYENGAR, Sundararaja S.: *Multi-Sensor Fusion: Fundamentals and Applications with Software*. Prentice Hall PTR, 1997
- [BP99] BLACKMAN, Samuel ; POPOLI, Robert: *Design and Analysis of Modern Tracking Systems*. Artech House, 1999
- [BS81] BAR-SHALOM, Yaakov: On the Track-to-Track Correlation Problem. In: *IEEE Transactions on Automatic Control* (1981), April, S. 571–572
- [BS89] BAR-SHALOM, Yaakov (Hrsg.): *MULTITARGET-MULTISENSOR TRACKING: APPLICATIONS AND ADVANCES*. Bd. I. Artech House, Inc., 1989
- [BSC86] BAR-SHALOM, Y. ; CAMPO, L.: The Effect of Common Process Noise on the Two-Sensor Fused-Track Covariance. In: *IEEE Transactions on Aerospace and Electronic Systems, AES* (1986), November, S. 803–805
- [BSG⁺04] BEHRINGER, Reinhold ; SUNDARESWARAN, Sundar ; GREGORY, Brian ; ELSLEY, Richard ; ADDISON, Bob ; GUTHMILLER, Wayne ; DAILY, Robert ; BEVLY, David: The DARPA Grand Challenge – Development of an Autonomous Vehicle. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2004

- [BSL93] BAR-SHALOM, Yaakov ; LI, X. R.: *Estimation and Tracking: Principles, Techniques and Software*. Artech House, Inc., 1993
- [BSLS00] BEUGNON, Céline ; SINGH, Tarunraj ; LLINAS, James ; SAHA, Rajat K.: Adaptive Track Fusion in a Multisensor Environment. In: *Proceedings of the IEEE Conference on Information Fusion*, 2000
- [BSMM97] BRONSTEIN, Ilja N. ; SEMENDJAEV, Konstantin A. ; MUSIOL, Gerhard ; MÜHLIG, Heiner: *Taschenbuch der Mathematik*. Verlag Harri Deutsch, 1997
- [CNR04] CASTRO, Daniel ; NUNES, Urbano ; RUANO, Antonio: FEATURE EXTRACTION FOR MOVING OBJECTS TRACKING SYSTEM IN INDOOR ENVIRONMENTS. In: *Proceedings of the 5th IVAC Symposium on Intelligent Autonomous Vehicles*, 2004
- [Cra04] CRAMER, Heiko: *Modelle zur multisensoriellen Erfassung der Fahrzeugumfeldes mit Hilfe von Schätzverfahren*, Technische Universität Chemnitz, Diss., 2004
- [CSBS97] CHANG, K. C. ; SAHA, R. K. ; BAR-SHALOM, Y.: On Optimal Track-to-Track Fusion. In: *IEEE Transactions on Aerospace and Electronic Systems, AES* (1997), Oktober, S. 1271–1275
- [CTS98] CHANG, K. C. ; ; TIAN, Zhi ; SAHA, R. K.: Performance Evaluation of Track Fusion with Information Filter. In: *Proceedings of the IEEE Conference on Multisource-Multisensor Information Fusion*, 1998, S. 648–655
- [Dem68] DEMPSTER, Arthur: A Generalization of Bayesian Inference. In: *Journal of the Royal Statistical Society* 30 (1968), S. 205–247
- [Dez02] DEZERT, J.: An introduction to the theory of plausible and paradoxical reasoning. In: *Proceedings of NM & A 02, International Conference on Numerical methods and Applications*, 2002
- [DN93] DONGES, Axel ; NOLL, Reinhard: *Lasermesstechnik – Grundlagen und Anwendungen*. Hüthig Buch Verlag Heidelberg, 1993
- [Dol05] DOLIWA, Peter: *Erweiterung eines Sensorsystems zur Umgebungserfassung durch Sensordatenfusion*, Technische Universität Carolo-Wilhelmina zu Braunschweig, Diplomarbeit, 2005
- [Elf89] ELFES, Alberto: *Occupancy Grids: A Probabilistic Framework for Robot Perception and Navigation*, Department of Electrical and Computer Engineering, Carnegie Mellon University, Diss., 1989
- [FLD03] FUERSTENBERG, Kay C. ; LINZMEIER, Dirk T. ; DIETMAYER, Klaus C. J.: Pedestrian Recognition and Tracking of Vehicles using a vehicle based Multilayer Laserscanner. In: *Proceedings of 10th World Congress on Intelligent Transport Systems*, 2003

- [FM97] FIXSEN, D. ; MAHLER, R. P. S.: The Modified Dempster-Shafer Approach to Classification. In: *IEEE Transactions on Systems, Man and Cybernetics* 27 (1997)
- [FPZ03] FLETCHER, Luke ; PETERSSON, Lars ; ZELINSKY, Alexander: Driver Assistance Systems based on Vision In and Out of Vehicles. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2003
- [Fri01] FRISK, E.: *Residual generation for Fault Diagnosis*, Linköpings Universitet, Diss., 2001
- [Ger91] GERTLER, J. J.: Analytical redundancy methods in fault detection and isolation – survey and synthesis. In: *Proceedings of the IFAC Symposium on Fault Detection, Supervision Safety Technical Processes*, 1991
- [ger98] *Fault Detection and Diagnosis in Engineering Systems*. Marcel Dekker, 1998
- [GFL01] GERN, Axel ; FRANKE, Uwe ; LEVI, Paul: Robust Vehicle Tracking Fusing Radar and Vision. In: *Proceedings of the IEEE Conference on Multisensor Fusion and Integration for Intelligent Systems*, 2001
- [GWF03] GEHRIG, Stefan K. ; WAGNER, Sebastian ; FRANKE, Uwe: System Architecture for an Intersection Assistant Fusing Image, Map, and GPS Information. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2003
- [Hae05] HAENNI, Rolf: Shedding New Light on Zadeh’s Criticism of Dempster’s Rule of Combination. In: *Proceedings of the IEEE Conference on Information Fusion*, 2005
- [hig04] Rundum sicher. In: *HIGHTECHREPORT* Bd. 2. DaimlerChrysler AG, 2004, S. 50–53
- [HKF05] HENFTLING, Hermann ; KLOTZBÜCHER, Dirk ; FRANK, Christian: Ultra Wide Band 24GHz Sequential Lobing Radar for Automotive Applications. In: *Proceedings of the International Radar Symposium 2005*, 2005
- [Hou62] HOUGH, P.: Method and means for recognizing complex patterns, u.s. patent no. 3,069,654 / HelpMate Robotics Inc. 1962. – Forschungsbericht
- [Hud02] HUDER, Bernhard: *Einführung in die Radartechnik*. B. G. Teubner Stuttgart Leipzig, 2002
- [IG04] ISHIDA, Shinnosuke ; GAYKO, Jens E.: Development, Evaluation and Introduction of a Lane Keeping Assistance System. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2004
- [IPNDS05] ISSING, M. ; PFEIFFER, S. ; NGUYEN-DOBINSKY, T. ; SCHINDLER, V.: Automatische Prognose der Verletzungsschwere zur Optimierung der Dispositionsentscheidung des Rettungsdienstes. In: *VDI-Berichte: Innovativer Kfz-Insassen- und Partnerschutz* Bd. 1911, VDI Verlag GmbH, 2005

- [JLRW04] JORDAN, R. ; LUCAS, B. ; RANDLER, M. ; WILHELM, U.: Safety Application Specific Requirements on the Data Processing of Environmental Sensors. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2004
- [JN04] JANSSEN, Holger ; NIEHSEN, Wolfgang: Vehicle Surround Sensing based on Information Fusion of Monocular Video and Digital Map. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2004
- [Kal60] KALMAN, R. E.: An New Approach to Linear Filtering and Prediction Problems. In: *Transactions of the ASME – Journal of Basic Engineering*, 1960
- [KFA⁺04] KRUSE, Frank ; FÖLSTER, Florian ; AHRHOLDT, Malte ; ROHLING, Hermann ; MEINECKE, Marc-Michael ; TO, Thanh-Binh: Target Classification based on Near-Distance Radar Sensors. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2004
- [Kle99] KLEIN: *Sensor Data Fusion*. Artech House, 1999
- [Klu00] KLUPSCH, Michael: *Objektorientierte Daten- und Zeitmodelle für die Echtzeit-Bildfolgenauswertung*, Institut für Informatik der Technischen Universität München, Diss., 2000
- [KMR02] KRUSE, F. ; MILCH, S. ; ROHLING, H.: Multi Sensor System for Obstacle Detection in Train Applications. In: *Proceedings of the GRS 2002*, 2002
- [LB05] LARSSON, Johan ; BROXVALL, Mathias: Fast Laser Based Feature Recognition. In: *Proc. of the 3rd Swedish Workshop on Autonomous Robotics*, 2005
- [Lin03] LINZMEIER, Dirk: *Sensor- und Objektmodellgestützte Assoziation mit Kalman-Filtern*, Universität Ulm, Diplomarbeit, 2003
- [LMDD04] LINZMEIER, Dirk T. ; MEKHAIEL, Moheb ; DICKMANN, Juergen ; DIETMAYER, Klaus C. J.: Pedestrian Detection with Thermopiles using an Occupancy Grid. In: *Proceedings of IEEE Intelligent Transportation Systems*, 2004
- [LSAD04] LINZMEIER, Dirk T. ; SKUTEK, Michael ; ABAY, Temel ; DIETMAYER, Klaus C. J.: Grid-based Optimal Sensor Arrangement within a Sensor Array for 2-D Position Estimation. In: *Proceedings of SPIE European Symposium on Optics/Photonics in Security and Defence*, 2004
- [Lud02] LUDLOFF, Albrecht: *Handbuch Radar und Radarsignalverarbeitung*. Vieweg Verlagsgesellschaft, 2002
- [LVMD05] LINZMEIER, Dirk ; VOGT, Dominik ; MEKHAIEL, Moheb ; DIETMAYER, Klaus: Fusion of Object Type Information from Radar and Thermopile Sensors. In: *IEEE Sensors Journal* (2005)
- [Mö4] MÜHLHÄUSSER, Jochen: *Segmentierung der Daten eines Laserscanners*, Fachhochschule Ulm, Diplomarbeit, 2004

- [May79] MAYBECK, Peter S.: *Stochastic models, estimation and control*. Bd. 1. Academic Press, Inc., 1979
- [MBN04] MENDES, Abel ; BENTO, Luis C. ; NUNES, Urbano: Multi-Target Detection and Tracking with a Laserscanner. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2004
- [MC96] MANIKAS, T.W. ; CAIN, J.T.: Genetic Algorithms vs. Simulated Annealing: A Comparison of Approaches for Solving the Circuit Partitioning Problem / University of Pittsburgh, Dept. of Electrical Engineering. 1996 (TR-96-101). – Forschungsbericht
- [ME85] MORAVEC, H. P. ; ELFES, A.: High resolution maps from wide angle sonar. In: *Proceedings of the IEEE International Conference on Robotics and Automation*, 1985
- [Mol05] MOLL, Christoph: *Documentation for Trigger Algorithm*. 2005. – Technische Dokumentation, DaimlerChrysler AG
- [Mor00] MORITZ, Rainer: Pre-crash Sensing – Functional Evolution based on Short Range Radar Sensor Platform. In: *SAE Technical Papers Series, 2000-01-2718*, 2000
- [MS03] MEIS, Urban ; SCHNEIDER, Robert: Radar Image Acquisition and Interpretation for Automotive Applications. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2003
- [NK03] NICO KAEMPCHEN, Klaus D.: Data Synchronization Strategies for Multi-Sensor Fusion. In: *Proceedings of 10th World Congress on Intelligent Transportation Systems*, 2003
- [NMTS05] NGUYEN, Viet ; MARTINELLI, Agostino ; TOMATIS, Nicola ; SIEGWART, Roland: A Comparison of Line Extraction Algorithms using 2D Laser Rangefinder for Indoor Mobile Robotics. In: *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2005
- [ORB04] OZGUNER, Umit ; REDMILL, Keith A. ; BROGGI, Alberto: Team TerraMax and the DARPA Grand Challenge: A General Overview. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2004
- [PS02] PANTAVUNGKOUR, Sompoch ; SHIBASAKI, Ryosuke: Feature Object Detection on the urban road surface by The Application of Three Line Scanner Imagery. In: *Proceedings of the 23rd Asian Conference on Remote Sensing (ACRS)*, 2002
- [Sah96] SAHA, R. K.: Effect of Common Process Noise on Two-Sensor Track Fusion. In: *Guidance, Control and Dynamics* (1996), Juli, S. 829–835
- [SB05] SCHÖNEBURG, Rodolfo ; BREITLING, Thomas: ENHANCEMENT OF ACTIVE & PASSIVE STAFETY BY FUTURE PRE-SAFE SYSTEMS. In: *Proceedings of the 19th International Technical Conference on the Enhanced Safety of Vehicles (ESV)*, 2005

- [Sch96] SCHÜRMANN, Jürgen: *Pattern Classification – A Unified View of Statistical and Neural Approaches*. John Wiley & Sons, Inc., 1996
- [Sch05] SCHERF, Oliver: Identifikation und quantitative Bewertung von Verbesserungspotentialen bei der Kombination passiver und aktiver Fahrzeugsicherheitssysteme. In: *VDI-Berichte: Innovativer Kfz-Insassen- und Partnerschutz* Bd. 1911, VDI Verlag GmbH, 2005
- [Sha76] SHAFFER, Glenn: *A mathematical theory of evidence*. Princeton University Press, 1976
- [SHRE00] STILLER, C. ; HIPPE, J. ; RÖSSIG, C. ; EWALD, A.: Multisensor obstacle detection and tracking. In: *Image and Vision Computing Journal* Bd. 18(5), 2000
- [SIAD03] SALA, Gianguido ; INAUDI, Domenico ; ALESSANDRETTI, Giancarlo ; DOMSCH, Christian: EFFECTIVENESS OF PRE-CRASH SYSTEM IN CHAMELEON. In: *Proceedings of the 10th Worldcongress and Exhibition on Intelligent Transportation Systems and Services*, 2003
- [SK71] SINGER, R. A. ; KANYUCK, A. J.: Computer Control of Multiple Site Track Correlation. In: *Automatica* Bd. 7, 1971, S. 455–462
- [Sko70] SKOLNIK, Merrill I.: *Radar Handbook*. McGraw-Hill Professional Publishing, 1970
- [Sko00] SKOLNIK, Merrill I.: *Introduction to Radar Systems*. McGraw-Hill Education, 2000
- [SL05] SKUTEK, Michael ; LINZMEIER, Dirk T.: Fusion von Sensordaten am Beispiel von Sicherheitsanwendungen in der Automobiltechnik. In: *at - Automatisierungstechnik* (2005)
- [SLWA05] SKUTEK, Michael ; LINZMEIER, Dirk ; WANIELIK, Gerd ; APPENRODT, Nils: A PreCrash System based on Sensor Data Fusion of Laser Scanner and Short Range Radars. In: *Proceedings of the IEEE Conference on Information Fusion*, 2005
- [SMBD02] SUN, Z. ; MILLER, R. ; BEBIS, G. ; DiMEO, D.: A Real Time Precrash Vehicle Detection System. In: *Proceedings of the IEEE Workshop on Application of Computer Vision*, 2002
- [SMW03] SKUTEK, Michael ; MEKHAIEL, Moheb ; WANIELIK, Gerd: A PreCrash System based on Radar for Automotive Applications. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2003
- [SSK03] SCHANZ, Alexaner ; SPIEKER, Andreas ; KUHNERT, Klaus-Dieter: Autonomous Parking in Subterranean Garages – A Look at the Position Estimation. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2003
- [Sud03] SUDANO, J. J.: A Generalized Belief Fusion Algorithm. In: *Proceedings of the IEEE Conference on Information Fusion*, 2003

- [TCG00] TANGO, F. ; CARREA, P. ; GOBETTO, E.: The Development of a Smart Pre-Crash System – the CHAMELEON project. In: *Proceedings of the 7th World Congress and Exhibition on Intelligent Transportation Systems and Services*, 2000
- [TKK⁺03] TOKORO, S. ; KURODA, K. ; KAWAKUBO, A. ; FUJITA, K. ; FUJINAMI, H.: Electronically Scanned Millimeter-wave Radar for Pre-Crash Safety and Adaptive Cruise Control System. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2003
- [TMK⁺04] TOKORO, S. ; MORIIZUMI, K. ; KAWASAKI, T. ; NAGAO, T. ; ABE, K. ; FUJITA, K.: Sensor Fusion System for Pre-Crash Safety System. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2004
- [ueb] *Die generalisierte Hough Transformation*. Übungsunterlagen zur LV Bildanalyse, Department of Computer Vision and Remote Sensing, Technische Universität Berlin,
- [Uzu05a] UZUNALI, Mustafa: *Extension of a system for environment recognition using a grid-based multi-sensor data fusion approach*, Universität Duisburg-Essen, Diplomarbeit, 2005
- [Uzu05b] UZUNALI, Mustafa: *Sensor Fault Detection: Development and Implementation of an Approach for the Quality Estimation of Sensor Data*. Studienarbeit, 2005
- [Vog05] VOGT, Dominik: *A Data Fusion System for Pedestrian Protection*, Department of Measurement, Control and Microtechnology, University of Ulm, Diplomarbeit, 2005
- [VRYK03] VENKATASUBRAMANIAN, Venkat ; RENGASWAMY, Raghunathan ; YIN, Kewen ; KAVURI, Surya N.: A review of process fault detection and diagnosis Part I: Quantitative model-based methods. In: *Computers and Chemical Engineering* 27 (2003), S. 293–311
- [Wal98] WALD, L.: A European proposal for terms of reference in data fusion. In: *International Archives of Photogrammetry and Remote Sensing* Bd. XXXII, 1998, S. 651–654
- [WB01] WELCH, Greg ; BISHOP, Gary: *An Introduction to the Kalman Filter*. 2001
- [WCD76] WILLNER, D. ; CHANG, C. ; DUNN, K. P.: Kalman Filter Algorithms for a Multisensor System. In: *Proceedings of the IEEE Conference on Decision and Control*, 1976, S. 570–574
- [WL90] WALTZ, Edward L. ; LLINAS, James: *Multisensor Data Fusion*. Artech House, Inc, 1990
- [WMO⁺93] WATANABE, Takamoto ; MAKINO, Yasuaki ; OHTSUKA, Yoshinori ; AKITA, Shigeyuki ; HATTORI, Tadashi: A CMOS time-to-digital-converter LSI with half-nanosecond resolution using a ring gate delay line. In: *IEEE TRANS. ELECTRON*. Bd. E76-C, 1993

- [Wu04] WU, Min: *Development of a Tracking Algorithm of Automotive System for Traffic Security*, Universität Stuttgart, Diplomarbeit, 2004
- [YYFK03] YANG, Lee ; YANG, Ji H. ; FERON, Eric ; KULKARNI, Vishwesh: Development of a Performance-Based Approach for a Rear-End Collision Warning and Avoidance System for Automobiles. In: *Proceedings of the IEEE Intelligent Vehicles Conference*, 2003
- [Zom91] ZOMOTOR, Adam: *Fahrwerktechnik: Fahrverhalten*. Vogel Buchverlag, Würzburg, 1991
- [ZY87] ZADEH, Lofti A. ; YAGER, R.R.: *Fuzzy Sets and Applications: Selected Papers by L.A. Zadeh*. John Wiley & Sons, 1987

Lebenslauf

Persönliche Daten

Name: Michael Skutek
Geburtsdatum: 16. Mai 1976
Geburtsort: Karl-Marx-Stadt

Schulbildung

09/1982–05/1990 Polytechnische Oberschule „Robert Koch“ in Chemnitz
09/1990–05/1994 Gymnasium „Werner Heisenberg“ in Chemnitz

Studium

10/1994–09/1995 Studium der Elektrotechnik an der Technischen Universität Chemnitz
10/1995–07/1996 Urlaubssemester (Unterbrechung durch Wehrdienst)
08/1996–02/2001 Fortsetzung und Abschluß des Studiums der Elektrotechnik an der Technischen Universität Chemnitz

Praktika

06/1994–07/1994 Grundpraktikum bei Fa. Eltrik GmbH in Chemnitz
10/1999–03/2000 Fachpraktikum bei Fa. Infineon AG in Düsseldorf

Praktische Arbeiten

01/1998–09/1999 Hilfwissenschaftliche Tätigkeiten an der Professur Schaltungs- und Systementwurf der Technischen Universität Chemnitz

Berufliche Tätigkeiten

03/2001–05/2001 Tätigkeit als wissenschaftlicher Mitarbeiter an der Professur Nachrichtentechnik der Technischen Universität Chemnitz
08/2001–12/2005 Tätigkeit als wissenschaftlicher Mitarbeiter an der Professur Nachrichtentechnik der Technischen Universität Chemnitz im Bereich „Multisensorielle Umgebungserfassung“ in Zusammenarbeit mit der DaimlerChrysler AG (Forschungszentrum Ulm)
seit 02/2006 Tätigkeit als Ingenieur in der Vorentwicklung Fahrerassistenzsysteme der Hella KGaA Hueck & Co.